

## **An Efficient Method for Automatic Multi-Class Classification of SD-OCT Images of Human Eye Based on RNFL layer and the IS/OS Junction Detection and Ensemble Decision Tree**

**Shamekhi, Sina**

Assistant Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran

### **ARTICLE INFO**

DOI: 10.22041/ijbme.2022.545364.1741

Received: 21 December 2021

Revised: 5/5/2022 – 29/6/2022 – 3/7/2022 – 5/7/2022

Accepted: 13 July 2022

### **KEYWORDS**

*SD-OCT*  
*Retina*  
*Frangi*  
*Ensemble Decision Tree*  
*Classification*


### **ABSTRACT**

Intuitive examination of retinal layers in Spectral-Domain Optical Coherence Tomography (SD-OCT) images is one of the main methods used by physicians to diagnose retinal diseases. This method faces challenges such as noise and image complexity and the proximity of retinal layers. In recent years, the automatic diagnosis of retinal diseases has become an important clinical issue in computer vision. In this research, a new method for efficient multi-class automatic classification of SD-OCT images has been proposed. This method consists of five stages, preprocessing, layer recognition, feature extraction, and image classification. Examination of the shape of the RNFL layer and IS/OS junction as a clinical method is influential in physicians' decisions to diagnose retinal diseases. Therefore, in this study, inspired by this clinical diagnosis method, the RNFL layer, and the IS/OS junction have been detected by a new method based on the Frangi vessel enhancement algorithm and the gradient of the image. Then, by extracting and selecting several efficient features from the curves of the layers, an algorithm based on the ensemble decision tree has been proposed for classifying SD-OCT images of the retina and presented as a MATLAB application. The proposed method has been evaluated using images of two well-known databases of Duke and Kermany. Based on the results, precision, sensitivity, specificity, accuracy, miss rate and F1-score of the proposed method in Duke database were equal to 98.7, 98.8, 99.4, 99.1, 1.3, and 98.7, respectively, and in Kermany database were 96.8, 96.7, 98.9, 98.4, 3.2 and 96.7 respectively. The results show the superiority of the proposed method compared to other comparative methods. In summary, the use of efficient features of retinal effective layers and a powerful algorithm for classification has improved the performance of the proposed method compared to previous more complex methods.

### **\*Corresponding Author**

<b>Address</b>	Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran
<b>Postal Code</b>	53318-17634
<b>E-Mail</b>	shamekhi@sut.ac.ir
<b>Tel</b>	+98-41-33458455
<b>Fax</b>	+98-41-33458455





## یک روش کارآمد برای طبقه‌بندی چندکلاسه‌ی خودکار تصاویر SD-OCT چشم انسان بر پایه‌ی استخراج لایه‌ی RNFL و پیوند IS/OS شبکه‌ی و الگوریتم درخت تصمیم ترکیبی

شامخی، سینا

استادیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

### مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2022.545364.1741

ثبت در سامانه: ۳۰ آذر ۱۴۰۰ بازنگری: ۱۴۰۱/۲/۱۵ - ۱۴۰۱/۴/۸ - ۱۴۰۱/۴/۱۲ - ۱۴۰۱/۴/۱۴ - پذیرش: ۲۲ تیر ۱۴۰۱

### چکیده

### واژه‌های کلیدی

بررسی شهودی لایه‌های شبکه‌ی در تصاویر برش‌نگاری همدوسی اپتیکی حوزه‌ی طیف (SD-OCT) یکی از روش‌های اصلی مورد استفاده‌ی پزشکان برای تشخیص بیماری‌های شبکه‌ی است. این روش با چالش‌هایی مانند نویز، پیچیدگی تصاویر و نزدیکی لایه‌های شبکه‌ی مواجه می‌باشد. در سال‌های اخیر تشخیص خودکار بیماری‌های شبکه‌ی چشم به یکی از موضوعات مهم بالینی در حوزه‌ی بینایی کامپیوتر تبدیل شده است. در این تحقیق روشی جدید برای طبقه‌بندی کارآمد چندکلاسه‌ی خودکار تصاویر SD-OCT ارائه شده که متشکل از پنج مرحله‌ی پیش‌پردازش، تشخیص لایه‌ها، استخراج ویژگی‌ها، کاهش بعد، و طبقه‌بندی تصویر است. بررسی شکل لایه‌ی RNFL و پیوند IS/OS به عنوان روشی بالینی در تصمیم‌گیری‌های پزشکان برای تشخیص بیماری‌های شبکه‌ی موثر است. از این رو در این پژوهش با الهام از این روش تشخیص بالینی، لایه‌ی RNFL و پیوند IS/OS توسط روشی جدید مبتنی بر الگوریتم بهبود رگ فرنگی و گرادیان تصویر تشخیص داده شده است. سپس با استخراج و انتخاب انواعی از ویژگی‌های موثر از لایه‌ها، الگوریتمی بر پایه‌ی درخت تصمیم ترکیبی برای طبقه‌بندی تصاویر شبکه‌ی پیشنهاد شده و در قالب یک نرم‌افزار کاربردی در متلب ارائه شده است. روش پیشنهادی روی تصاویر دو پایگاه داده‌ی شناخته شده‌ی دوک و کرمنی ارزیابی شده است. بر اساس نتایج، دقت، حساسیت، اختصاصیت، درستی، نرخ منفی نادرست و معیار F1 روش پیشنهادی در پایگاه داده‌ی دوک به ترتیب برابر با ۹۸/۷، ۹۸/۸، ۹۹/۴، ۹۹/۱، ۱/۳ و ۹۸/۷ درصد و در پایگاه کرمنی به ترتیب برابر با ۹۶/۸، ۹۶/۷، ۹۸/۹، ۹۸/۴، ۳/۲ و ۹۶/۷ درصد است. نتایج نشان‌دهنده‌ی برتری روش پیشنهادی در مقایسه با سایر روش‌های مقایسه‌ای است. در مجموع به کارگیری ویژگی‌های کارآمد از لایه‌های تاثیرگذار شبکه‌ی و توانمندی روش طبقه‌بندی، موجب ارتقای عمل‌کرد روش پیشنهادی در مقایسه با روش‌های پیچیده‌تر پیشین شده است.

برش‌نگاری همدوسی اپتیکی  
حوزه‌ی طیف  
شبکه  
فرنگی  
درخت تصمیم ترکیبی  
طبقه‌بندی

### \*نویسنده‌ی مسئول

استادیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

نشانی

تلفن ۵۸۴۵۸۴۵۵-۴۱-۹۸+

۵۳۳۱۸-۱۷۶۳۴

کد پستی

دورنگار ۵۸۴۵۸۴۵۵-۴۱-۹۸+


shamekhi@sut.ac.ir

پست الکترونیک



## ۱- مقدمه

چشم به عنوان یکی از اندام حسی مهم در انسان در معرض بیماری‌های گوناگونی قرار دارد که بخش عمده‌ای از این بیماری‌ها، شبکیه<sup>۱</sup> را درگیر می‌کنند. شبکیه مهم‌ترین و داخلی‌ترین بخش چشم در تشکیل تصویر بوده که از لایه‌های مختلف بسیار نازک و شفاف تشکیل شده است. آسیب‌های وارده به هر یک از این لایه‌ها می‌تواند به طیف وسیعی از آسیب‌های شبکیه یا رتینوپاتی<sup>۲</sup> منجر شود [۱]. رتینوپاتی‌ها بسته به شدت می‌توانند موجب تاری دید تا کوری شوند. بر اساس آخرین گزارش‌های منتشر شده توسط سازمان جهانی بهداشت در حال حاضر در جهان نزدیک به ۳۴۲ میلیون نفر به بیماری‌های مرتبط با شبکیه‌ی چشم مبتلا هستند که از این تعداد ۱۹۶ میلیون نفر دچار بیماری زوال ماکولای وابسته به سن<sup>۳</sup> (AMD) و ۱۴۶ میلیون نفر نیز درگیر رتینوپاتی دیابتی<sup>۴</sup> (DR) می‌باشند [۲]. از آن‌جا که این بیماری‌ها می‌توانند موجب کوری در بیمار شده و زندگی فرد را تحت تاثیر جدی قرار دهند، ارائه‌ی روش‌های جدید و موثر برای تشخیص خودکار این نوع از بیماری‌ها بر پایه‌ی تصاویر اخذ شده از شبکیه به اولویتی برای پژوهش‌گران تبدیل شده است [۳، ۴]. یکی از اصلی‌ترین روش‌های تصویربرداری جهت تشخیص بیماری‌های شبکیه‌ی چشم، برش‌نگاری همدوسی اپتیکی (OCT) است. در این روش ویژگی لایه‌های بافت‌های چشم به کمک اصل تداخل امواج نور بازتابیده از بافت و نور بازتابیده از آینه‌ی مرجع به دست می‌آید. برش‌نگاری همدوسی اپتیکی حوزه‌ی طیف<sup>۵</sup> (SD-OCT) نوع جدیدتری از ساختارهای OCT است که در آن با اضافه کردن یک دستگاه طیف‌نما، تداخل نورهای بازگشتی از تمام سطوح بافتی به طور هم‌زمان ارزیابی می‌شود. این اقدام موجب افزایش حساسیت دستگاه و بهبود کیفیت و وضوح تصاویر بافت‌های مختلف چشم می‌شود [۵]. نمونه‌ای از تصاویر SD-OCT برگرفته از پایگاه داده‌ی دانشگاه دوک [۶] در شکل (۱) نشان داده شده است. در این شکل، SD-OCT شبکیه‌ی سالم در قسمت الف، شبکیه‌ی مبتلا به DME در قسمت ب و شبکیه‌ی مبتلا به AMD در قسمت ج ارائه شده است. در شکل (۱-د) نیز نمونه‌ای از تصاویر حجمی یا سه‌بعدی SD-OCT نشان داده شده است. استفاده از تصاویر حجمی به تشخیص بهتر نواحی آسیب دیده کمک می‌کند. البته به کارگیری این تصاویر محدودیت‌هایی مانند حافظه‌ی مورد نیاز را در پی دارد [۶].



شکل (۱) - نمونه‌ی تصاویر OCT از شبکیه‌ی چشم انسان، الف) شبکیه‌ی سالم، ب) نمونه‌ی DME، ج) نمونه‌ی AMD [۶]، د) تصویر حجمی (سه‌بعدی) [۷]

مطابق شکل (۱)، تصاویر SD-OCT با چالش‌هایی مانند نویز و آرتیفکت، پیچیدگی‌های موجود در تصاویر و نزدیک بودن لایه‌های آناتومیکی شبکیه مواجه هستند. این موارد، تشخیص و طبقه‌بندی دستی و مبتنی بر مشاهده‌ی تصاویر را با مشکلاتی مواجه می‌کنند. بنابراین وجود یک مرحله جهت پیش‌پردازش این تصاویر ضروری است [۶]. در تحقیقات پیشین و برای حذف نویز موجود در این تصاویر از روش‌هایی مانند فیلتر میانه [۸] و فیلتر انتشار پیچیده‌ی غیرخطی [۹] استفاده شده است. هم‌چنین در پردازش تصاویر از روش‌هایی مانند به کارگیری فیلتر انتشار [۱۰]، استفاده از تبدیل موجک مورلت جهت بازنمایی ضایعات [۱۱] و یا بررسی‌های ساختاری و ریخت‌شناسی [۱۲] استفاده شده است. کاهش نویز و به کارگیری روش‌های پردازش تصاویر، زمینه را برای بخش‌بندی و طبقه‌بندی تصاویر SD-OCT مهیا می‌سازد. در سال‌های اخیر طبقه‌بندی خودکار تصاویر SD-OCT و تشخیص بیماری‌های شبکیه در قالب روش‌های کامپیوتری متنوع مورد توجه محققان بسیاری قرار گرفته است. سرینویاسان و هم‌کارانش در سال ۲۰۱۴ ضمن ارائه‌ی روشی مبتنی بر ماشین بردار پشتیبان<sup>۶</sup> (SVM) و هیستوگرام گرادیان‌های جهت‌دار<sup>۷</sup> (HOG)، یک پایگاه داده از تصاویر SD-OCT را در سه دسته‌ی سالم، AMD و DME ارائه کردند [۶]. بردار ویژگی در این تحقیق از تصاویر حجمی و بدون توجه به لایه‌های آناتومیکی به دست آمده است. این مساله موجب افزایش پیچیدگی، بروز مشکلات محاسباتی و کمبود حافظه در اجرای الگوریتم شده است. از سوی دیگر امکان به کارگیری روش مذکور در تک تصویر SD-OCT نیز

<sup>۵</sup> Spectral Domain Optical Coherence Tomography

<sup>۶</sup> Support Vector Machine

<sup>۷</sup> Histogram of Oriented Gradients

<sup>۱</sup> Retina

<sup>۲</sup> Retinopathy

<sup>۳</sup> Age-Related Macular Degeneration

<sup>۴</sup> Diabetic Retinopathy

طبقه‌بندی تصاویر SD-OCT هدف اصلی بیش‌تر این تحقیقات بوده است. هم‌چنین پس از انتشار پایگاه داده‌ی کرمی و به دلیل وجود تعداد تصاویر بالای این پایگاه داده، بیش‌تر تحقیقات اخیر بر اساس روش‌های یادگیری ژرف انجام شده است. مسلماً اجرای شبکه‌های عصبی ژرف که ذاتاً دارای پارامترها و پیچیدگی بیش‌تری هستند، نیازمند هزینه‌های سخت‌افزاری و زمانی بالاتری نیز می‌باشد. از سوی دیگر عدم به کارگیری ویژگی‌های موثر که انطباق بیش‌تری با ریشه‌های آسیب‌شناختی بیماری‌ها دارند، ضعف برخی از تحقیقات قبلی است. این موضوع زمانی از اهمیت بیش‌تری برخوردار می‌شود که هدف، تشخیص بیماری در حالت تک تصویر SD-OCT باشد. موضوع مهم دیگر در تحقیقات پیشین، ارتقای عمل‌کرد طبقه‌بند در شاخص‌های مختلف و به طور هم‌زمان می‌باشد. مشاهده می‌شود که در برخی از تحقیقات پیشین با افزایش حساسیت، اختصاصیت از دست رفته است (و یا برعکس).

روش پیشنهادی این تحقیق که با رویکرد حل مشکلات اشاره شده در بالا طراحی شده است به طور خلاصه به شرح زیر می‌باشد. در این پژوهش پس از پیش‌پردازش تصاویر، گرادیان تصویر محاسبه شده است. سپس با استفاده از روش تشخیص رنگ فرنگی [۲۰] که برای اولین بار برای این هدف استفاده شده، خطوط لایه‌ی فیبر عصبی شبکه‌ی<sup>۶</sup> (RNFL) و ناحیه‌ی پیوند IS/OS تشخیص داده شده و ویژگی‌های مرتبط استخراج شده است. شکل این لایه‌ها و تغییراتی که به دلیل بروز بیماری‌های شبکه‌ی در آن‌ها رخ می‌دهد یکی از روش‌های مورد استفاده‌ی پزشکان متخصص برای تشخیص این بیماری‌ها است. پس از تشکیل ماتریس ویژگی‌ها به کمک روش‌های گوناگون کاهش بعد، ویژگی‌های موثر انتخاب شده و جهت طبقه‌بندی به کار گرفته شده است. در روش پیشنهادی ارائه شده در این تحقیق از طبقه‌بند درخت تصمیم ترکیبی<sup>۷</sup> چندکلاسه برای طبقه‌بندی تصاویر SD-OCT استفاده شده است. هم‌چنین در این پژوهش دو پایگاه داده‌ی تصاویر برچسب‌گذاری شده‌ی دوک و کرمی به کار گرفته شده است [۶، ۱۶]. تعداد کلاس‌های موجود در هر یک از پایگاه‌های داده‌ی به کار گرفته شده متفاوت و محدود است که این موضوع یکی از محدودیت‌های روش پیشنهادی به شمار می‌رود.

با توجه به موارد ذکر شده در بالا، نوآوری‌های اصلی این تحقیق به شرح زیر است.

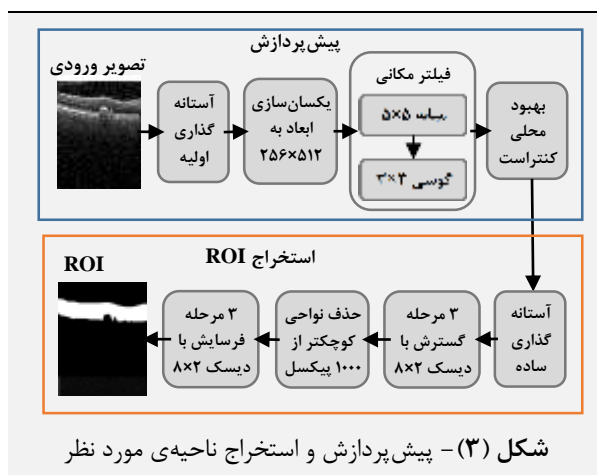
بررسی نشده است. پایگاه داده‌ی تحقیق مذکور که از این پس با نام پایگاه داده‌ی دوک از آن یاد می‌شود در سال ۲۰۱۵ توسط لمایتر و هم‌کارانش در تحقیقی مبتنی بر الگوهای محلی دودویی مورد استفاده قرار گرفته است [۱۳]. هدف این تحقیق بهبود تشخیص بیماری DME در تصاویر حجمی SD-OCT بوده است. سیدیبه و هم‌کارانش در سال ۲۰۱۷ با ارائه‌ی روشی مبتنی بر مدل ترکیبی گوسی و به کارگیری پایگاه داده‌ی دوک و پایگاه داده‌ی SERI روشی برای تشخیص بیماری DME ارائه کردند [۱۴]. بر اساس نتایج، روش آن‌ها قادر به ارائه‌ی هم‌زمان حساسیت و اختصاصیت بالا در هر دو پایگاه داده نبوده است. در سال ۲۰۱۷ گرندس و هم‌کارانش از روش جنگل تصادفی<sup>۱</sup> (RF) و ویژگی‌های آسیب‌شناسی مانند ضخامت لایه‌ی داخلی، خارجی و مرکزی شبکه‌ی، برای بخش‌بندی و طبقه‌بندی تصاویر DME استفاده کردند [۱۵]. حسین و هم‌کارانش در سال ۲۰۱۸ یک الگوریتم طبقه‌بندی مبتنی بر جنگل تصادفی برای شناسایی خودکار افراد مبتلا به AMD و DME در پایگاه داده‌ی دوک و سه پایگاه داده‌ی دیگر ارائه کردند [۷]. در سال ۲۰۱۸ کرمی و هم‌کارانش ضمن ارائه‌ی یک پایگاه داده‌ی جدید [۱۶] و نسبتاً بزرگ از تصاویر SD-OCT شامل تصاویر شبکه‌ی سالم، DME، نئوواسکولاریزیشن کروئیدال<sup>۲</sup> (CNV) و دروسن<sup>۳</sup>، الگوریتمی مبتنی بر یادگیری ژرف<sup>۴</sup> را برای ارتقای طبقه‌بندی تصاویر SD-OCT ارائه کردند [۱۷]. در سال ۲۰۱۸ رونگ و هم‌کارانش از شبکه‌های عصبی همگشتی<sup>۵</sup> (CNN) برای طبقه‌بندی تک تصویرهای پایگاه داده‌ی دوک استفاده کردند [۱۸]. تشخیص بیماری از روی تک تصویر دشوارتر از تشخیص بر اساس تصاویر حجمی SD-OCT است. با این حال واریانس صحت طبقه‌بندی روش مذکور در آزمون‌های مختلف زیاد بوده است. در سال‌های اخیر به کارگیری روش‌های یادگیری ژرف در طبقه‌بندی تصاویر SD-OCT گسترش یافته است. به طور ویژه مطالعات صورت گرفته روی پایگاه داده‌ی کرمی بیش‌تر بر روش‌های یادگیری ژرف استوار است. در سال ۲۰۲۱ لو و هم‌کارانش پایگاه‌های داده‌ی کرمی و دوک را در الگوریتمی مبتنی بر شبکه‌های ژرف نیمه‌نظارت‌شده مورد استفاده قرار دادند [۱۹]. پیچیدگی بالا و وابستگی به کیفیت داده‌های آموزش، از نقاط ضعف تحقیق مذکور محسوب می‌شود. با توجه به تحقیقاتی که در سال‌های اخیر صورت گرفته است می‌توان نتیجه گرفت که ارائه‌ی الگوریتم‌های قدرتمندتر جهت

<sup>۵</sup> Convolutional Neural Network<sup>۶</sup> Retinal Nerve Fiber Layer<sup>۷</sup> Ensemble Model<sup>۱</sup> Random Forest<sup>۲</sup> Choroidal Neovascularization<sup>۳</sup> DRUSEN<sup>۴</sup> Deep Learning

است. پایگاه‌های داده‌ی اول توسط محققان دانشگاه دوک و هاروارد ارائه شده که در این تحقیق با نام پایگاه داده‌ی دوک از آن یاد شده و متشکل از ۱۴۰۷ تصویر نرمال، ۱۱۰۱ تصویر DME و ۷۲۳ تصویر AMD است [۶]. پایگاه داده‌ی دوم مجموعه‌ی تصاویر ارائه شده توسط کرمی و هم‌کارانش بوده که شامل ۴ دسته‌ی سالم، DME، دروسن و CNV در دو پوشه‌ی داده‌های آموزش و آزمون است [۱۶]. تعداد تصاویر در پوشه‌های آموزش در هر یک از دسته‌های سالم، DME، دروسن و CNV به ترتیب برابر با ۲۶۳۱۵، ۱۱۳۴۸، ۸۶۱۶ و ۳۷۲۰۵ و تعداد تصاویر هر دسته در پوشه‌ی آزمون برابر با ۲۵۰ است. لازم به ذکر است که تمام آزمایشات برای انتخاب بهترین الگوریتم برای روش پیشنهادی ابتدا روی پایگاه داده‌ی دوک انجام شده و برای تایید نتایج، روش پیشنهادی روی پایگاه داده‌ی کرمی نیز اعمال شده است.

## ۲-۲- پیش پردازش و استخراج ناحیه‌ی مورد نظر

اولین مرحله از روش پیشنهادی، پیش‌پردازش تصاویر بوده که بخش‌های مختلف آن در شکل (۳) نشان داده شده است.



شکل (۳) - پیش‌پردازش و استخراج ناحیه‌ی مورد نظر

اهداف این بخش شامل تنظیم ابعاد تصاویر، حذف نویز و استخراج ناحیه‌ی مورد نظر<sup>۱</sup> است. مراحل این بخش از الگوریتم و هم‌چنین دلایل انتخاب هر یک از آن‌ها به شرح زیر است.

۱- در ابتدا نواحی نویز پس‌زمینه و نواحی با شدت روشنایی بالا حذف شده است. برای این کار به کمک یک مرحله‌ی آستانه‌گذاری اولیه، مقدار شدت روشنایی (I) پیکسل‌هایی با  $I \geq 250$  یا  $I \leq 5$  برابر صفر قرار داده شده است.

۲- جهت افزایش کارایی روش‌ها و یکسان‌سازی مقیاس‌های تصاویر به ویژه در مواجهه با تصاویر پایگاه‌های داده‌ی متفاوت، اندازه‌ی تمام تصاویر ورودی به ۲۵۶×۵۱۲ تغییر داده شده است.

۱- با الهام از روش بالینی تشخیص بیماری‌های شبکیه بر پایه‌ی لایه‌ی RNFL و پیوند IS/OS، ویژگی‌های آناتومیکی موثرتر برای طبقه‌بندی مورد استفاده قرار گرفته است.

۲- ارائه‌ی روشی مبتنی بر یادگیری ماشین معمول که در مقایسه با روش‌های یادگیری ژرف دارای تعداد کم‌تری از پارامترها بوده و نتایج بهتری حاصل کرده است.

۳- ارائه‌ی الگوریتمی خودکار در قالب یک اپلیکیشن متلب برای طبقه‌بندی تک تصویر SD-OCT که در شاخص‌های گوناگون به ویژه خطای عدم تشخیص بیمار به طور هم‌زمان عمل‌کرد بهتر و پایداری در مقایسه با تحقیقات پیشین دارد.

۴- استفاده از یک روش جدید در تشخیص لایه‌های آناتومیکی مبتنی بر الگوریتم بهبود رگ‌فرنگی.

۵- به کارگیری الگوریتم‌های تجزیه‌ی سیگنال و انتروپی‌های حاصل از آن‌ها که به استخراج بهتر ویژگی‌ها کمک نموده است. در ادامه در بخش دوم روش پیشنهادی به همراه پایگاه‌های داده‌ی به کار گرفته شده مورد بررسی قرار گرفته است. در بخش سوم نتایج تحقیق ارائه شده و مورد مقایسه و ارزیابی قرار گرفته و در پایان نیز جمع‌بندی و نتیجه‌گیری انجام شده است.

## ۲- مواد و روش‌ها

در این بخش در ابتدا پایگاه‌های داده‌ی به کار گرفته شده در این تحقیق معرفی شده و سپس روش پیشنهادی این تحقیق توضیح داده شده است. همان‌طور که در شکل (۲) نشان داده شده، روش پیشنهادی از بخش‌های پیش‌پردازش، استخراج خطوط، استخراج ویژگی‌ها، کاهش بعد و طبقه‌بندی تشکیل شده که در ادامه هر یک از این مراحل بررسی شده است.



شکل (۲) - طرح‌واره‌ی روش پیشنهادی

## ۲-۱- پایگاه‌های داده‌ی تصویر

در این تحقیق از دو پایگاه داده‌ی معتبر از تصاویر SD-OCT جهت آموزش، ارزیابی و مقایسه‌ی نتایج پژوهش استفاده شده

<sup>۱</sup> Region of Interest (ROI)

۱- در گام نخست با ضرب تصویر ROI در تصویر فیلتر شده از مرحله‌ی قبل، گرادیان در داخل ناحیه‌ی ROI و در راستاهای  $x$  و  $y$  محاسبه شده است.

۲- پس از محاسبه‌ی گرادیان، مقادیر مثبت و بزرگتر از یک‌دهم بیشینه‌ی هر گرادیان حفظ شده و مابقی برابر با صفر قرار داده شده است. این اقدام با هدف انتخاب لبه‌های افزایشی هر تصویر صورت گرفته است تا از تکرار لبه و انتخاب لبه‌های داخلی و لبه‌های ضعیف نویزی جلوگیری شود. سپس اندازه‌ی بردار گرادیان‌های باقی‌مانده محاسبه شده است.

۳- برای بهبود خطوط و یافتن خطوط لبه‌ی به هم پیوسته، از الگوریتم چندمقیاسه‌ی بهبود رگ ارائه شده توسط فرنگی و هم‌کارانش [۲۰] استفاده شده است. اساس کار در این روش ارائه‌ی اندازه‌هایی<sup>۲</sup> بر حسب مقادیر ویژه‌ی ماتریس هسین<sup>۳</sup> تصویر (H) بوده که در مقیاس‌های مختلف محاسبه شده است. در این روش پس از محاسبه‌ی ماتریس هسین تصویر، مقادیر ویژه‌ی این ماتریس ( $\lambda_1$  و  $\lambda_2$ ) برای محاسبه‌ی معیارهای تشخیص دهنده‌ی ساختارها و خط محاسبه شده است. در این محاسبات مقادیر ویژه به صورت  $|\lambda_2| \geq |\lambda_1|$  مرتب شده است. این معیار و رابطه‌ی نهایی در روابط (۳-۱) درج شده است [۲۰].

$$R_B = \frac{\lambda_1}{\lambda_2} \quad (۱)$$

$$S = \|H\|_F = \sqrt{\lambda_1^2 + \lambda_2^2} \quad (۲)$$

$$V_o = \begin{cases} 0, & \text{if } \lambda_2 > 0 \\ \exp\left(-\frac{R_B^2}{2\beta^2}\right) \left(1 - \exp\left(-\frac{S^2}{2c^2}\right)\right) \end{cases} \quad (۳)$$

در این روابط  $\beta$  و  $c$  مقادیر آستانه برای کنترل و اندازه‌ی ساختار S است. رابطه‌ی (۱) بیان‌گر معیار دایره‌ای<sup>۴</sup> ( $R_B$ ) است. از آن جا که در نواحی دایره‌ای مقادیر ویژه یا مثبت بزرگ یا منفی بزرگ هستند،  $R_B \rightarrow 1$  برقرار بوده و در نواحی خطی نیز به دلیل بزرگ شدن  $|\lambda_2|$ ،  $R_B \rightarrow 0$  برقرار است و در نتیجه با تعیین مقدار مناسبی برای  $\beta$  می‌توان عبارت مناسبی در توان تابع نمایی تولید کرد تا تفکیک خوبی بین نواحی خطی و دایره‌ای ایجاد شود. عبارت نمایی اول در رابطه‌ی (۳) را می‌توان معیار تشخیص خط در این رابطه نام‌گذاری کرد. هم‌چنین این محاسبات باید در ناحیه‌هایی صورت گیرد که در آن جسم وجود دارد و جسم در ناحیه‌هایی قرار دارد که هسین در آن‌ها دارای مقادیر ویژه‌ی بزرگی است. با استفاده از مقدار S (رابطه‌ی ۲) که بیان‌گر اندازه‌ی مقادیر ویژه می‌باشد نواحی دارای مقادیر

۳- با وجود حذف برخی از نواحی نویز در مرحله‌ی آستانه‌گذاری اولیه، نواحی کوچکی با شدت‌های متفاوت در تصاویر باقی مانده که این نواحی با کمک یک فیلتر میانه با ابعاد  $5 \times 5$  و یک فیلتر گوسی با ابعاد  $2 \times 2$  حذف شده است. لازم به ذکر است که مرحله‌ی ۱ موجب ایجاد نواحی کوچک سیاهی (صفر) شده که معمولاً با شدت‌های روشنایی بالایی احاطه شده‌اند. این نواحی با به کارگیری فیلتر میانه اصلاح شده است. هم‌چنین نرم کردن تصویر به کمک فیلتر گوسی، مشکلات ایجاد شده به دلیل یکسان‌سازی ابعاد تصاویر را برطرف کرده است.

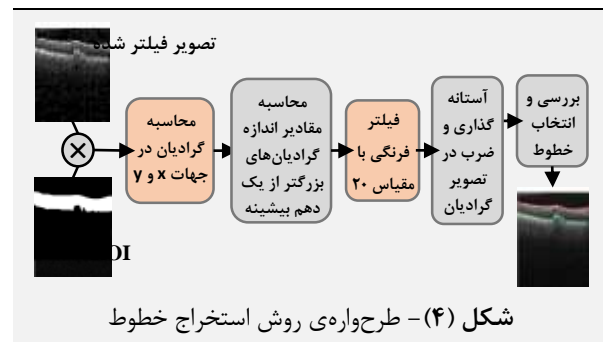
۴- با اعمال روش بهبود محلی کنتراست با آگاهی از لبه [۲۱]، کنتراست تصویر برای تفکیک بهتر مرزها بهبود داده شده است.

۵- جهت استخراج ROI، در ابتدا از یک مرحله‌ی آستانه‌گذاری ساده استفاده شده است.

۶- حفره‌های احتمالی ایجاد شده‌ی ناشی از مرحله‌ی ۵ ابتدا توسط ۳ بار گسترش با جز ساختاری دیسک با ابعاد  $2 \times 8$ ، سپس حذف نواحی کوچک‌تر از ۱۰۰۰ پیکسل و در نهایت فرسایش با دیسک با ابعاد  $2 \times 8$  انجام شده است. به این ترتیب یک نقاب برای انتخاب ناحیه‌ی مورد نظر (ROI) به دست آمده که برای استخراج خطوط در مراحل بعدی به کار برده شده است.

## ۲-۳- استخراج لایه‌ی RNFL و پیوند IS/OS

همان‌طور که پیش‌تر اشاره شد، به دلیل اهمیت بالینی لایه‌ی RNFL و پیوند IS/OS در تشخیص بیماری‌های شبکیه، الگوریتم ارائه شده در این تحقیق بر پایه‌ی به کارگیری ویژگی‌های استخراج شده از این دو لایه‌ی موثر استوار است. استخراج خطوط این لایه‌ها به دلیل آرتیفکت‌ها و پیچیدگی‌های تصاویر SD-OCT، با چالش‌هایی مانند عدم تشخیص صحیح و تکه‌تکه شدن خطوط همراه است. جهت غلبه بر این مشکلات، الگوریتم ترکیبی که در شکل (۴) نشان داده شده برای تشخیص خطوط پیشنهاد شده که به شرح زیر است.



<sup>۳</sup> Hessian

<sup>۴</sup> Blobness Measure

<sup>۱</sup> Edge-Aware Local Contrast Manipulation of Images

<sup>۲</sup> Measures

در شکل (۵) انتخاب نقطه‌ی متعلق به خط بالاتر در نقطه‌ی ۱ به آسانی ممکن است اما در انتخاب نقطه‌ی متعلق به خط دوم، از میان نقاط ۲ و ۳ نقطه‌ی دارای مقدار بیش‌تر انتخاب می‌شود.

## ۴-۲- استخراج ویژگی


در الگوریتم پیشنهادی این تحقیق پس از استخراج خطوط لایه‌ی RNLf و ناحیه‌ی پیوند IS/OS، فاصله‌ی خطوط، تجزیه‌ی حالت وردشی<sup>۱</sup> (VMD) و تبدیل موجک تجربی<sup>۲</sup> (EWT) خطوط، هم‌چنین انحنای<sup>۳</sup> هر یک از خطوط و تفاضل انحنایها برای محاسبه‌ی ویژگی‌های خطی و غیرخطی به کار گرفته شده است. با توجه به بررسی تصاویر مختلف و تفاوت‌های شهودی حاصل از این مطالعه، مشخص شده که فاصله‌ی دو خط می‌تواند عاملی مهم در تشخیص بی‌نظمی محسوب شود. از این رو فاصله‌ی بین دو خط اصلی تشخیص داده شده به عنوان یکی از سیگنال‌های اصلی جهت محاسبه‌ی ویژگی‌ها به کار گرفته شده است. الگوهای حادث در خطوط RNLf و ناحیه‌ی پیوند IS/OS، به گونه‌ای است که به نظر می‌رسد تجزیه به سیگنال‌های تشکیل دهنده در تشخیص تغییرات کلی (در مقیاس بالا) و جزئی (در مقیاس پایین) می‌تواند به تشخیص بهتر الگوها کمک کند. از این رو در این تحقیق از روش‌های تجزیه‌ی سیگنال نیز برای جداسازی مولفه‌های تشکیل دهنده‌ی سیگنال‌ها استفاده شده است. هم‌چنین بر اساس مطالعات این تحقیق تا کنون از انحنای خطوط در این نوع از مطالعات استفاده نشده بنابراین از ویژگی‌های مستخرج از انحنای خطوط نیز استفاده شده است. مطابق جدول (۱)، این ویژگی‌ها که در مجموع ۱۷۶ مورد هستند شامل بیشینه، کمینه، میانگین، واریانس، جذر مجموع مربعات، فرکانس میانی طیف توان، انتروپی‌های شنون<sup>۴</sup> [۲۲]، نمونه<sup>۵</sup> [۲۳]، رنی<sup>۶</sup> [۲۴]، تی‌سالیس<sup>۷</sup> [۲۵]، تقریبی<sup>۸</sup> [۲۶]، بعد فرکتال<sup>۹</sup> [۲۷] و میانگین و واریانس تبدیل موجک‌های سیملت ۴ و فجرکروفکین<sup>۱۰</sup> [۲۸] می‌باشند.

در انتخاب اولیه‌ی ویژگی‌ها، هدف تحقیق و الگوی سیگنال‌های مورد استفاده در نظر گرفته شده است. خطوط در تصاویر سالم دارای الگوی نرم و بدون تغییرات شدید هستند و در تصاویر مربوط به بیماری‌ها دارای تغییرات و اعوجاج‌های قابل توجهی می‌باشند. بنابراین ویژگی‌ها برای جداسازی بهتر این تفاوت‌ها و

ویژه‌ی قابل توجه مشخص شده است. این مقدار در عبارت دوم رابطه‌ی (۳) قرار داده شده و با تنظیم پارامتر کنترل مناسب (c)، ناحیه‌هایی که دارای مقادیر ویژه‌ی نویزی و ضعیف هستند حذف شده است. در تنظیمات الگوریتم پیشنهادی و جهت حذف آثار آرتیفکت‌های موجود، حداکثر مقیاس الگوریتم فرنگی برابر با ۲۰ و پارامترهای کنترل تشخیص ساختار نیز برابر با ۵ انتخاب شده است.

۴- در ادامه بر تصویر حاصل از الگوریتم فرنگی یک مرحله‌ی آستانه‌گذاری اعمال شده است. سپس حاصل ضرب تصویر نقاب در تصویر اندازه‌ی بردار گرادیان، برای استخراج محل صحیح خطوط (لایه‌ها) محاسبه شده است. دلیل استفاده از این حاصل ضرب (که در ادامه به آن تصویر اصلاح شده‌ی بردار گرادیان گفته می‌شود)، در دسترس بودن شدت گرادیان در تصویر نهایی برای تعیین محل صحیح خطوط است. در صورت عدم وجود مقدار اندازه‌ی گرادیان در تصویر نهایی، مکان بیشینه‌های محلی قابل تشخیص نخواهد بود.

۵- در انتها نیز الگوریتم انتخاب نقاط پیوسته‌ی خطوط که در این تحقیق برای تشکیل خطوط مورد نظر پیشنهاد شده، اعمال شده است. برای تشکیل خطوط مورد نظر، از هر یک از نواحی باید صرفاً یک نقطه در راستای عمودی انتخاب شود. بنابراین پیش از بررسی بیشینه در تصویر اصلاح شده‌ی بردار گرادیان، باید وضعیت تعلق نقاط موجود در خطوط پیوسته به صرفاً یکی از خطوط موجود تعیین شود. همان‌طور که در شکل (۵) خطی به رنگ سبز روی تصویر آستانه‌گذاری شده‌ی فیلتر فرنگی ترسیم شده، انتخاب نقاط متعلق به هر یک از خطوط در قالب جاروب افقی تصویر توسط پنجره‌ی لغزانی صورت گرفته است. این پنجره دارای عرض ۱ پیکسل و طولی برابر با کل تصویر است و از چپ به راست تصویر را جاروب می‌کند.



شکل (۵) - انتخاب نقاط متعلق به خطوط

<sup>۶</sup> Renyi

<sup>۷</sup> Tsallis

<sup>۸</sup> Approximate

<sup>۹</sup> Fractal Dimension

<sup>۱۰</sup> Fejér-Korovkin

<sup>۱</sup> Variational Mode Decomposition

<sup>۲</sup> Empirical Wavelet Transform

<sup>۳</sup> Curvature

<sup>۴</sup> Shannon

<sup>۵</sup> Sample

تغییرات شهودی دارای محتوای فرکانسی بالاتری هستند. این تغییرات از ذات آسیب‌های آناتومیکی وارد به بافت شبکه‌ی به عنوان مثال آسیب‌های وارد به عروق نشات می‌گیرند. از سوی دیگر از آن‌جا که تغییرات در دامنه، انحنا و تجزیه‌های سیگنال خطوط در تصاویر مربوط به شبکه‌های آسیب دیده دارای الگوهای تغییرات زیاد و با مکان وقوع متغیر هستند، استفاده از انتروپی به عنوان معیار عدم قطعیت یا بی‌نظمی [۲۹] می‌تواند در تشخیص این الگوها کمک نماید. در این تحقیق از انتروپی شونون به عنوان یکی از پایه‌ای‌ترین انتروپی‌ها برای تشخیص بی‌نظمی‌ها استفاده شده است. این انتروپی برای متغیر تصادفی گسسته‌ی  $X$  با تابع احتمال  $p(x)$  به صورت رابطه‌ی (۴) محاسبه می‌شود [۲۹].

$$H(X) = - \sum_{x \in X} p(x) \log p(x) \quad (4)$$

ویژگی دیگر استخراج شده از سیگنال‌های اصلی و تجزیه شده، انتروپی نمونه بوده که قابلیت بیان رفتار تصادفی سیگنال را داشته، حساسیت کم‌تری به نویز دارد و از عمل کرد بهتری در سیگنال‌هایی با طول پایین برخوردار است [۲۹]. از این رو با توجه به طول محدود سیگنال‌های خطوط، این ویژگی در این تحقیق به کار گرفته شده است. در این تحقیق بعد نشاننده<sup>۳</sup> این انتروپی ۵ و مقدار آستانه‌ی مقایسه ۰/۲ در نظر گرفته شده است. جهت دریافت جزئیات بیشتر مربوط به این انتروپی می‌توان به مقاله‌ی ریچمن و هم‌کارانش [۲۳] مراجعه کرد.

انتروپی‌های رنی [۲۴] و تی‌سالیس [۲۵] تعمیمی وابسته به پارامتر از انتروپی شونون هستند [۳۰]. اگر  $p(x_i)$  توزیع احتمال برای یک مجموعه‌ی محدود باشد، انتروپی رنی مرتبه‌ی  $\alpha$  به صورت رابطه‌ی (۵) بیان می‌شود.

$$R_{en}(X) = \frac{1}{1-\alpha} \ln \sum_{i=1}^n p(x_i)^\alpha \quad (5)$$

در این رابطه  $0 < \alpha < 1$  بوده و مشخص است که وقتی  $\alpha$  به ۱ میل کند، انتروپی رنی به انتروپی شونون میل می‌کند. در این تحقیق مقدار  $\alpha$  برابر با ۰/۵ انتخاب شده است. انتروپی تی‌سالیس مرتبه‌ی  $\alpha$  به کار گرفته شده در مجموعه‌ی ویژگی‌ها نیز به صورت رابطه‌ی (۶) محاسبه می‌شود.

$$R_{en}(X) = \frac{1}{1-\alpha} \left( 1 - \sum_{i=1}^n p(x_i)^\alpha \right) \quad (6)$$

با توجه به دو مورد اصلی اشاره شده در بالا انتخاب شده است. ویژگی‌هایی مانند بیشینه، کمینه، میانگین، واریانس و جذر مجموع مربعات برای استخراج و تشخیص تغییرات در دامنه‌ی سیگنال‌های اصلی و تجزیه شده انتخاب شده است.

جدول (۱) - ویژگی‌های استخراج شده

تعداد	ویژگی‌ها	سیگنال
۱۵	بیشینه، کمینه، واریانس، RMS، فرکانس میانی، انتروپی‌های شونون، نمونه، رنی، تیسالیس و تقریبی، بعد فرکتال و میانگین و واریانس ضرایب تبدیل موجک‌های سیملت ۴ و فجرکروفکین ۴ (مجموعه‌ی ۱)	خط ۱ (RNLF)
۱۵	مجموعه‌ی ۱	خط ۲ (پیوند IS/OS)
۱۵	مجموعه‌ی ۱	فاصله‌ی خطوط ۱ و ۲
۱۱	بیشینه، کمینه، واریانس، RMS، فرکانس میانی، انتروپی‌های شونون، نمونه، رنی، تیسالیس و تقریبی و بعد فرکتال (مجموعه‌ی ۲)	imf <sup>۱</sup> اول از تبدیل VMD خط ۱
۱۱	مجموعه‌ی ۲	imf دوم از تبدیل VMD خط ۱
۱۱	مجموعه‌ی ۲	imf اول از تبدیل VMD خط ۲
۱۱	مجموعه‌ی ۲	imf دوم از تبدیل VMD خط ۲
۱۱	مجموعه‌ی ۲	mra <sup>۲</sup> اول از تبدیل EWT خط ۱
۱۱	مجموعه‌ی ۲	mra دوم از تبدیل EWT خط ۱
۱۱	مجموعه‌ی ۲	mra اول از تبدیل EWT خط ۲
۱۱	مجموعه‌ی ۲	mra دوم از تبدیل EWT خط ۲
۱۵	مجموعه‌ی ۱	انحنای خط ۱
۱۵	مجموعه‌ی ۱	انحنای خط ۲
۱۳	مجموعه‌ی ۱ به جز انتروپی‌های تی‌سالیس و نمونه (حذف به دلیل مشکلات محاسبات و نتایج تجربی)	تفاضل انحنای ۱ و ۲
۱۷۶		مجموع

در تمام سیگنال‌های حاصل از خطوط مربوط به شبکه‌های سالم، تغییرات دامنه و انحنا با فرکانس بسیار پایینی صورت می‌گیرد. در صورتی که در خطوط مربوط به تصاویر ناسالم

<sup>۳</sup> Embedding Entropy

<sup>۱</sup> Intrinsic Mode Functions

<sup>۲</sup> Multiresolution Analysis



می‌توانند بیان موثری از متغیر پاسخ باشند. این الگوریتم با استفاده از اطلاعات متقابل<sup>۵</sup>، افزونگی<sup>۶</sup> یک مجموعه‌ی ویژگی را کمینه کرده و ارتباط مجموعه‌ی ویژگی را با متغیر پاسخ بیشینه می‌کند [۳۱]. روش Chi-2 ویژگی‌ها را بر اساس نتایج آزمون Chi-2 رتبه‌بندی می‌کند [۳۲]. در حقیقت با محاسبه‌ی آزمون Chi-2، استقلال ویژگی با متغیر پاسخ ارزیابی شده و بر اساس محاسبه‌ی مقادیر p، رتبه‌بندی انجام می‌شود. در روش NCA برای وزن‌دهی ویژگی‌ها از نوع جدیدی از نزدیک‌ترین همسایگی استفاده می‌شود. این روش بر خلاف روش‌هایی مانند آزمون Chi-2 از تخمین پارامتری برای رتبه‌بندی استفاده نمی‌کند. روش NCA با بیشینه‌سازی میزان صحت یک طبقه‌بندی از نوع کنارگذاشتن یکی<sup>۷</sup>، یک بردار وزن‌دهی ویژگی را همراه با یک ترم منظم‌سازی یاد می‌گیرد [۳۳]. در الگوریتم Relief ایده‌ی اصلی این است که کیفیت ویژگی‌ها را بر اساس میزان تمایز مقادیر آن‌ها بین نمونه‌هایی که نزدیک به یکدیگر هستند، تخمین بزند. تفاوت این جست‌وجو در این است که Relief دو همسایه‌ی نزدیک خود را جست‌وجو می‌کند (یکی از همان کلاس و دیگری از یک کلاس متفاوت) [۳۴]. آخرین روش تعبیه شده در GUI این تحقیق روش PCA است. در این روش بر خلاف سایر روش‌ها که ویژگی‌ها بر اساس وزن و یا امتیاز رتبه‌بندی می‌شوند، فضای ویژگی/متغیر جدیدی که همان مولفه‌های اساسی داده‌ها محسوب می‌شود، شکل می‌گیرد. این مولفه‌های اساسی متغیرهای جدیدی هستند که دارای واریانس بیشینه می‌باشند [۳۵].

به کارگیری انواع این روش‌های کاهش بعد که به صورت جداگانه اعمال شده‌اند، مقایسه‌ی عمل کرد هر یک از روش‌های کاهش بعد روی پایگاه‌های داده‌ی این تحقیق را ممکن کرده است. هم‌چنین با مقایسه‌ی نتایج، امکان انتخاب بهترین روش برای کاهش بعد در مجموعه‌ی ویژگی‌های این تحقیق فراهم شده است. ضمناً وجود انواع این روش‌های کاهش بعد در GUI ارائه شده، امکانات بیش‌تری در اختیار محققان قرار می‌دهد.

## ۲-۶- نرمال‌سازی و متعادل‌سازی

با توجه به این که داده‌های موجود در گروه‌های هر دو پایگاه داده در تعادل نیستند (نامتعادل<sup>۸</sup> هستند)، نتیجه‌ی به کارگیری داده‌هایی با تعداد برابر در هر گروه مورد ارزیابی قرار گرفته است. هم‌چنین جهت بررسی تاثیر نرمال‌سازی بردار ویژگی‌ها

یکی از کاربردهای بسیار مهم انترویی تی‌سالیس در تشخیص الگو است [۳۰]. از این رو در این تحقیق در مجموعه‌ی ویژگی‌های پیشنهادی و با مقدار  $\alpha$  برابر با ۰/۵ از این انترویی استفاده شده است.

آخرین انترویی به کار گرفته شده در مجموعه‌ی ویژگی‌های این تحقیق، انترویی تقریبی ارائه شده توسط پینکوس است [۲۶]. این انترویی راه‌کاری برای کمی‌سازی نظم در داده‌های حاصل از سیستم‌هایی است که اطلاعاتی در مورد آن در دسترس نمی‌باشد [۳۰]. در این انترویی مقادیر بعد نشاننده و مقدار آستانه به ترتیب برابر با ۵ و ۰/۲ انتخاب شده است. دلیل اصلی ارائه‌ی این نوع از انترویی‌ها، غلبه بر مشکل طول محدود در سیگنال‌ها است [۳۰]. به دلیل حجم بالای روابط از درج آن‌ها در این مقاله پرهیز شده است. خوانندگان برای اطلاع از جزئیات بیش‌تر می‌توانند به مقالات [۲۶، ۳۰] مراجعه فرمایند.

در این تحقیق برای شناسایی بهتر برخی از الگوهای موجود در خطوط و مرزهای نواحی، از میانگین و واریانس تبدیلات موجک سیملت ۴ و فجرکروفکین ۴ استفاده شده است. این تبدیلات با توجه به شکل تغییرات و آسیب‌های وارد در لایه‌های شبکه‌های ناسالم در مقایسه با شبکه‌های سالم قدرت تفکیک بهتری در آزمایشات تجربی این تحقیق از خود نشان دادند. به نحوی که در بررسی اولیه‌ی رتبه‌بندی، این موجک‌ها در مقایسه با سایر موجک‌های مورد استفاده در این تحقیق رتبه‌های بهتری را به خود اختصاص دادند. در این بررسی، انواع دیگری از موجک‌های در دسترس مانند موجک هار و دابچیز<sup>۱</sup> نیز مورد بررسی قرار گرفته است. در بخش نتایج با به کارگیری روش‌های مختلف انتخاب ویژگی، گزارشی از ویژگی‌های برتر انتخاب شده در این تحقیق ارائه شده است.

## ۲-۵- کاهش بعد

در این تحقیق علاوه بر بررسی نتایج به کارگیری کامل بردار ویژگی‌های پیشنهادی، جهت بررسی مدل‌هایی با تعداد ویژگی کم‌تر یا به بیانی دیگر با ابعاد فضای ویژگی کوچک‌تر، از روش‌های کاهش بعد MRMR<sup>۲</sup> [۳۱]، Chi-2 [۳۲]، تحلیل مولفه‌ی همسایگی<sup>۳</sup> (NCA) [۳۳]، ReliefF [۳۴] و هم‌چنین تحلیل مولفه‌های اساسی<sup>۴</sup> (PCA) استفاده شده است. الگوریتم MRMR مجموعه‌ی بهینه‌ای از ویژگی‌ها را پیدا می‌کند که به صورت متقابل و بیشینه، متفاوت هستند و

<sup>۵</sup> Mutual Information

<sup>۶</sup> Redundancy

<sup>۷</sup> Leave-One-Out

<sup>۸</sup> Imbalanced

<sup>۱</sup> Daubechies

<sup>۲</sup> Minimum Redundancy Maximum Relevance

<sup>۳</sup> Neighborhood Component Analysis

<sup>۴</sup> Principal Component Analysis

یک داده‌ی جدید بر اساس رای حداکثر تعیین می‌شود [۳۷]. الگوریتم‌های افزایش<sup>۴</sup> نوع دیگری از روش‌های ترکیبی هستند که در آن‌ها طبقه‌بندها نه به صورت مستقل بلکه به صورت متوالی ساخته می‌شوند طوری که طبقه‌بند بعدی وزن بیش‌تری را به اشتباهات طبقه‌بند قبلی اختصاص می‌دهد [۳۷].

در این تحقیق از الگوریتم طبقه‌بند ترکیبی ارائه شده در نرم‌افزار متلب نسخه‌ی 2021b استفاده شده است. این الگوریتم امکان به کارگیری الگوریتم‌های افزایش و بگینگ با طبقه‌بندهای پایه‌ی درخت تصمیم را فراهم ساخته است. نتایج اولیه در تنظیمات دستی انجام شده حاکی از عمل‌کرد مناسب این طبقه‌بند در مواجهه با مساله‌ی این تحقیق بوده است. بنابراین با فعال‌سازی امکان بهینه‌سازی بیزی، تعداد دوره‌ها و نرخ یادگیری بهینه شده است. هم‌چنین در اعمال روش پیشنهادی روی پایگاه داده‌ی کرمی، به دلیل عدم تعادل بالا در تعداد نمونه‌های هر گروه و از آن‌جا که بهینه‌سازی به روش RUSBoost در داده‌های نامتعادل عمل‌کرد بهتری دارد [۳۹] از این روش استفاده شده است. تعداد دوره‌های آموزش برابر با ۵۰۰، تعداد بیشینه‌ی انشعاب<sup>۵</sup>ها برابر با تعداد نمونه‌ها و نرخ یادگیری نیز برابر با ۰/۱ انتخاب شده است.

## ۲-۸- رابط کاربری گرافیکی<sup>۶</sup> طراحی شده

در این تحقیق جهت تسهیل کار کاربران، یک رابط کاربری گرافیکی (GUI) با نام SiOCT برای به کارگیری در محیط نرم‌افزار متلب ارائه شده است. تصویر صفحه‌ی اصلی این رابط در شکل (۶) نشان داده شده است. همان‌طور که مشاهده می‌شود امکانات وسیعی اعم از بارگذاری داده‌ها، انجام مراحل استخراج خطوط و استخراج ویژگی‌ها، کاهش بعد، متعادل کردن داده‌ها، نرمال‌سازی ویژگی‌ها و فعال‌سازی انواع روش‌های طبقه‌بندی در این GUI در اختیار کاربر قرار داده شده است. با وجود این که امکان ادغام تعداد دل‌خواه ویژگی برتر انتخاب شده توسط هر یک از روش‌های انتخاب ویژگی در این رابط کاربری قرار داده شده، این حالت ترکیبی در نتایج این تحقیق ارائه نشده است. این GUI قابلیت انجام دو فرایند آموزش و آزمون را در تمام روش‌های گنجانده شده در خود دارد. ضمناً SiOCT به همراه تمام توابع و داده‌های مرتبط در گیت‌هاب در دسترس عموم قرار داده شده است.<sup>۷</sup>

بر نتایج طبقه‌بندی، روش‌های نرمال‌سازی نمره‌ی  $z$  و نرمال‌سازی در محدوده‌ی [0,1] بررسی و ارزیابی شده است.

## ۲-۷- طبقه‌بندی با روش درخت تصمیم ترکیبی

یک مجموعه‌ی داده  $(x, y)$  متشکل از بردار ویژگی‌ها  $(x)$  و برچسب کلاس‌ها بوده و عموماً مساله‌ی اصلی در یادگیری ماشین یافتن تخمینی برابر  $h$  برای تابع  $f$  است که با  $y=f(x)$  رابطه‌ی بین بردار ویژگی‌ها و برچسب کلاس‌ها را در قالب یک طبقه‌بند بیان کند. در این روش‌ها جست‌وجو برای یافتن این تخمین، درون مجموعه‌ی توابع ممکن انجام شده که فرضیه‌ها نامیده می‌شوند. الگوریتم‌های یادگیری برای یافتن بهترین فرضیه، تطبیق تخمین  $h$  را روی تابع  $f$  ارزیابی نموده و بهترین را انتخاب می‌کنند [۳۶]. یکی از کارآمدترین و پرکاربردترین الگوریتم‌های یادگیری، درخت تصمیم بوده که دارای ساختاری درختی است. در این الگوریتم هر گره داخلی بیان‌گر یک آزمایش از ویژگی، هر شاخه نشان‌دهنده‌ی یکی از نتایج ممکن آزمایش و هر گره برگ نشان‌گر یک طبقه‌بند است [۳۷]. این روش برای انجام طبقه‌بندی، فضای فرضیه‌ای متشکل از درخت‌های تصمیم را جست‌وجو می‌کند. یک الگوریتم یادگیری درخت تصمیم با در نظر گرفتن درخت‌هایی که تنها یک ویژگی را آزمایش می‌کنند و انجام یک طبقه‌بندی فوری، فضای درخت‌ها را جست‌وجو می‌کند و سپس درخت را با جایگزینی یکی از برگ‌ها با آزمایش ویژگی دوم گسترش می‌دهد [۳۶]. الگوریتم‌های ترکیبی با روشی متفاوت با آن‌چه در بالا توضیح داده شد عمل می‌کنند. این روش‌ها به جای یافتن یک فرضیه‌ی بهترین برای بیان رابطه‌ی بین داده‌ها و برچسب، یک مجموعه از فرضیه‌ها که ترکیب نیز نامیده می‌شود را می‌سازند و در قالب نوعی رای‌گیری، پیش‌گویی برچسب برای داده‌ی جدید را انجام می‌دهند [۳۶]. در حقیقت یک طبقه‌بند ترکیبی طبقه‌بندی است که چند طبقه‌بند پایه را برای طبقه‌بندی نهایی ترکیب می‌کند. تجمیع خودرانداز<sup>۲</sup> که به صورت خلاصه با نام بگینگ<sup>۳</sup> شناخته می‌شود، یکی از الگوریتم‌های ترکیبی محسوب می‌شود [۳۸]. در این الگوریتم هر طبقه‌بند پایه که می‌تواند درخت تصمیم نیز باشد، روی یک مجموعه از داده‌های اولیه، آموزش می‌بیند. این مجموعه بر اساس روش نمونه‌برداری خودرانداز به صورت تصادفی انتخاب می‌شود. نتیجه‌ی طبقه‌بندی برای

<sup>۵</sup> Split

<sup>۶</sup> Graphical User Interface

<sup>۷</sup> <https://github.com/sshamekhi/SiOCT>

<sup>۱</sup> Z-Score

<sup>۲</sup> Bootstrap Aggregating

<sup>۳</sup> Bagging

<sup>۴</sup> Boosting



شکل (۶) - GUI طراحی شده در این تحقیق (SiOCT)


شناسایی افراد سالم نشان می‌دهد. نرخ منفی نادرست، به منظور ارزیابی خطای طبقه‌بند در تشخیص‌هایی است که به اشتباه سالم تشخیص داده شده‌اند. معیار F1 نیز اثر معیارهای دقت و حساسیت را به صورت موازی و هم‌زمان بررسی می‌کند.

### ۳- یافته‌ها و بحث

در این بخش نتایج حاصل از الگوریتم پیشنهادی و نرم‌افزار کاربردی طراحی شده در این تحقیق ارائه شده است. نتایج به صورت مرحله‌ای و مشابه روند به کار گرفته شده در بخش روش پیشنهادی توضیح داده شده است.

#### ۳-۱- نتایج پیش‌پردازش

نمونه‌ای از تصاویر خروجی مراحل پیش‌پردازش تصاویر شامل اعمال فیلترها و بهبود کنتراست تصاویر روی یک تصویر AMD از پایگاه داده‌ی کرمی در شکل (۷) نشان داده شده است.



شکل (۷) - نتایج پیش‌پردازش، الف) تصویر ورودی، ب) تصویر فیلتر شده، ج) بهبود کنتراست، د) نهایی

#### ۲-۹- معیارهای ارزیابی

معیارهای مورد استفاده در این تحقیق برای ارزیابی و مقایسه‌ی عمل‌کرد روش‌ها شامل دقت، حساسیت، اختصاصیت، درستی، نرخ منفی نادرست (FNR) و معیار F1 است که به ترتیب توسط روابط (۷) تا (۱۲) محاسبه می‌شوند [۳، ۴۰، ۴۱].

$$\text{دقت} = \frac{TP}{TP + FP} \quad (7)$$

$$\text{حساسیت} = \frac{TP}{TP + FN} \quad (8)$$

$$\text{اختصاصیت} = \frac{TN}{TN + FP} \quad (9)$$

$$\text{درستی} = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

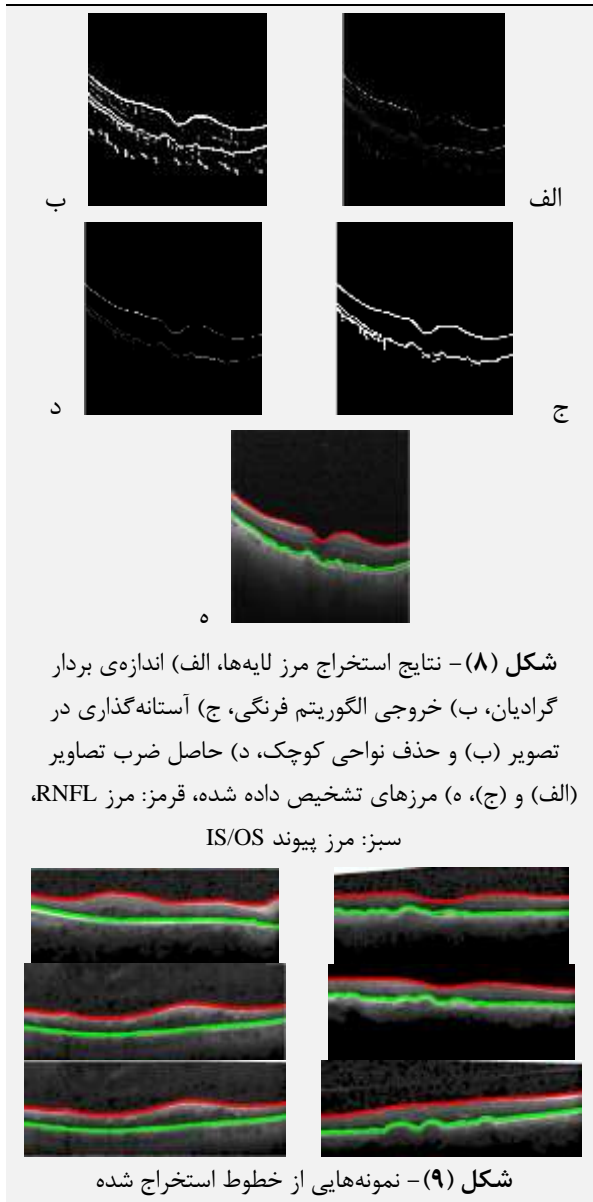
$$\text{نرخ منفی نادرست} = FNR = \frac{FN}{FN + TP} \quad (11)$$

$$F1 = \frac{2 \times \text{دقت} \times \text{حساسیت}}{\text{دقت} + \text{حساسیت}} \quad (12)$$

در این روابط TP نتایج مثبت درست، TN نتایج منفی درست، FP نتایج مثبت نادرست و FN نتایج منفی نادرست بوده که بر اساس داده‌های برچسب‌گذاری شده‌ی هر یک از پایگاه‌های داده مورد محاسبه قرار گرفته است. ضمناً محاسبه‌ی میانگین چند کلاس نیز متناسب با تعداد اعضای هر کلاس صورت گرفته است [۴۰]. با دقت در روابط این معیارها می‌توان نقش هر یک را در ارزیابی یک طبقه‌بند مورد تحلیل قرار داد. معیار دقت تعیین می‌کند که با چه نسبتی مثبت‌های اعلام شده توسط طبقه‌بند (نمونه‌های تشخیص داده شده به عنوان بیمار) درست هستند. معیار حساسیت توانایی طبقه‌بند را در شناسایی درست بیمار نشان می‌دهد. معیار اختصاصیت توانایی طبقه‌بند را در

در مراحل آموزش مورد استفاده قرار نگرفته است. روش‌های طبقه‌بندی که جهت مقایسه پیاده‌سازی شده‌اند شامل درخت تصمیم<sup>۳</sup> (DT)، k نزدیک‌ترین همسایه<sup>۴</sup> (KNN)، جنگل تصادفی، چندکلاسه‌ی SVM، الگوریتم بیز ساده<sup>۵</sup> و شبکه‌ی عصبی پیش‌خور<sup>۶</sup> است.

در ادامه در ابتدا نتایج حاصل از بررسی‌های جامع روی پایگاه داده‌ی دوک ارائه شده و سپس با استفاده از نتایج مذکور، مقایسه‌های تکمیلی روی پایگاه داده‌ی کرمی ارائه شده است.



### ۳-۳-۱- نتایج پایگاه داده‌ی دوک

در جدول‌های (۲) تا (۵) نتایج بررسی روش‌های پیشنهادی و مقایسه‌ای در زیرمجموعه‌ی تصاویر آزمون پایگاه داده‌ی دوک

### ۳-۲- نتایج استخراج لایه‌ی RNFL و پیوند IS/OS

نتایج کیفی مراحل مختلف پیشنهاد شده در بخش ۲-۳ برای استخراج لایه‌ها در تصاویر شکل (۸) نشان داده شده است. در شکل (۸-الف) تصویر اندازه‌ی بردار گرادیان تصویر نشان داده شده است. در شکل (۸-ب) نتیجه‌ی استفاده از الگوریتم بهبود رگ فرنگی روی تصویر (۸-الف) نشان داده شده است. نتیجه‌ی آستانه‌گذاری و حذف نواحی کوچک‌تر از ۱۰۰۰ پیکسل از تصویر (۸-ب) در شکل (۸-ج) نشان داده شده است. در شکل (۸-د) نیز حاصل ضرب شکل (۸-الف) در شکل (۸-ج) نشان داده شده است. در شکل (۸-ه) نتیجه‌ی بررسی بیشینه‌های محلی تصویر (۸-د) بر اساس آن‌چه در بخش ۲-۳ توضیح داده شده به تصویر کشیده شده است. در این شکل از خط قرمز برای نمایش لایه‌ی RNFL و از خط سبز برای نشان دادن پیوند IS/OS استفاده شده است. همان‌طور که مشاهده می‌شود روش پیشنهاد شده جهت استخراج مرز لایه‌ها از عمل کرد مناسبی برخوردار است. نمونه‌هایی از استخراج این خطوط در تصاویر مختلف در شکل (۹) نشان داده شده است. جهت ارزیابی شهودی، خطوط استخراج شده در تمام تصاویر پایگاه داده‌ی دوک و در تعداد بالایی از تصاویر پایگاه داده‌ی کرمی بررسی شده است. عملاً بررسی تمام خطوط استخراج شده در پایگاه داده‌ی کرمی به دلیل تعداد بالای تصاویر (بیش از ۸۴۰۰۰) غیرممکن است. در پایگاه‌های داده‌ی مورد استفاده، داده‌های حقیقت‌مبنای<sup>۱</sup> این خطوط در دسترس نیست، بنابراین ارزیابی کمی در این زمینه ممکن نمی‌باشد. با این حال واضح است که آثار استخراج صحیح این خطوط در نتایج کمی طبقه‌بندی موثر و مشهود خواهد بود.

### ۳-۳-۲- نتایج کمی طبقه‌بندی

در این بخش به بررسی نتایج کمی روش پیشنهادی این تحقیق جهت طبقه‌بندی داده‌ها در دو پایگاه داده‌ی دوک و کرمی پرداخته شده است. تمام جدول‌ها و نمودارهای ترسیم شده پس از ۱۰ بار انجام آزمایش روی داده‌ی به‌هم‌ریخته<sup>۲</sup> انجام شده و نتایج به صورت میانگین و انحراف معیار ارائه شده است. ضمناً در تمام پیاده‌سازی‌های پایگاه داده‌ی دوک، ۸۰٪ از داده به صورت تصادفی به عنوان داده‌ی آموزش و ۲۰٪ به عنوان داده‌ی آزمون مورد استفاده قرار گرفته است. پایگاه داده‌ی کرمی نیز مجموعه‌های مجزای آموزش و آزمون دارد که در این تحقیق از همان مجموعه‌ها استفاده شده است. تصاویر آزمون به هیچ وجه

<sup>۴</sup> K-Nearest Neighbors

<sup>۵</sup> Naïve Bayes

<sup>۶</sup> Feed Forward

<sup>۱</sup> Ground Truth

<sup>۲</sup> Shuffle

<sup>۳</sup> Decision Trees

بهبتری را با ۵۰ ویژگی برتر از ۱۷۶ ویژگی اولیه از خود نشان داده است. این ۵۰ ویژگی برتر که دارای ۹۹/۹ درصد مجموع امتیازات بوده‌اند، به ترتیب بر اساس امتیاز هر یک در جدول (۴) ارائه شده است. با توجه به ویژگی‌های مندرج در این جدول، مشخص است که انواع انتروپی‌های تی‌سالیس، نمونه و تقریبی تحقیق به ویژه انتروپی‌های تی‌سالیس، نمونه و تقریبی بیش‌ترین حضور را در ویژگی‌های برتر داشته‌اند. تفاضل خطوط نیز نقشی موثر در این ۵۰ ویژگی ایفا کرده است. اما باید به طور خاص به نقش استخراج تغییرات خطوط توسط روش‌های EWT و VMD اشاره کرد به طوری که مشاهده می‌شود بیش‌تر ویژگی‌های قرار گرفته در این مجموعه‌ی برتر از مولفه‌های سیگنال تجزیه شده توسط این دو روش محاسبه شده‌اند.

ارائه شده است. در جدول (۲) نتایج به کارگیری داده‌های کامل و داده‌های متعادل شده به همراه اعمال دو روش نرمال‌سازی نمره‌ی  $z$  و نرمال‌سازی در محدوده‌ی  $[0,1]$  ارائه شده است. همان‌طور که مشاهده می‌شود، نرمال‌سازی و متعادل‌سازی داده‌ها موجب بهبود آموزش و حصول نتایج آزمون بهتر در تمام معیارها شده است. در جدول (۳) نتایج مقایسه‌ی انواع روش‌های کاهش بعد روی داده‌های نامتعادل اولیه و داده‌های متعادل شده از پایگاه داده‌ی دوک نشان داده شده است. در ستون سوم این جدول نسبت درصدی امتیاز/وزن ویژگی‌های انتخاب شده به کل امتیاز/وزن ویژگی‌ها درج شده است. بر این اساس می‌توان نتیجه گرفت که در مساله‌ی این تحقیق و داده‌های مورد استفاده (پایگاه داده‌ی دوک)، روش NCA نتایج

**جدول (۲) - مقایسه‌ی حالات مختلف پیاده‌سازی روش پیشنهادی در حالت‌های مختلف به کارگیری پایگاه داده‌ی دوک (بر حسب درصد)**

معیار FI	FNR	درستی	اختصاصیت	حساسیت	دقت	نرمال‌سازی	متعادل/نامتعادل
۹۷/۷±۰/۶	۲/۳±۰/۶	۹۸/۴±۰/۴	۹۸/۵±۰/۴	۹۷/۷±۰/۶	۹۷/۸±۰/۶	-	نامتعادل (کل پایگاه)
۹۷/۸±۰/۴	۲/۲±۰/۴	۹۸/۵±۰/۳	۹۸/۶±۰/۳	۹۷/۸±۰/۴	۹۷/۸±۰/۴	نمره‌ی $z$	نامتعادل (کل پایگاه)
۹۸/۰±۰/۶	۲/۰±۰/۶	۹۸/۶±۰/۴	۹۸/۷±۰/۳	۹۸/۰±۰/۶	۹۸/۰±۰/۶	range [0 1]	نامتعادل (کل پایگاه)
۹۸/۳±۰/۵	۱/۷±۰/۵	۹۸/۹±۰/۳	۹۹/۲±۰/۲	۹۸/۳±۰/۵	۹۸/۴±۰/۴	-	متعادل شده
۹۸/۵±۰/۷	۱/۵±۰/۷	۹۹/۰±۰/۴	۹۹/۲±۰/۳	۹۸/۵±۰/۷	۹۸/۵±۰/۶	نمره‌ی $z$	متعادل شده
۹۸/۷±۰/۶	۱/۳±۰/۶	۹۹/۱±۰/۴	۹۹/۴±۰/۳	۹۸/۸±۰/۶	۹۸/۷±۰/۶	range [0 1]	متعادل شده

**جدول (۳) - نتایج حالات مختلف پیاده‌سازی به کارگیری روش‌های کاهش بعد (۵۰ ویژگی برتر) روی پایگاه داده‌ی دوک (بر حسب درصد)**

معیار FI	FNR	درستی	اختصاصیت	حساسیت	دقت	امتیاز	کاهش ابعاد	متعادل/نامتعادل
۹۶/۹±۰/۳	۳/۱±۰/۲	۹۷/۹±۰/۲	۹۸/۱±۰/۲	۹۶/۹±۰/۲	۹۶/۹±۰/۲	۷۹/۶	MRMR	نامتعادل (کل پایگاه)
۹۳/۵±۱/۰	۶/۵±۰/۱	۹۵/۵±۰/۷	۹۶/۰±۰/۶	۹۳/۵±۱/۰	۹۳/۶±۰/۱	۴۵/۷	Chi-2	نامتعادل (کل پایگاه)
۹۷/۶±۰/۵	۲/۴±۰/۴	۹۸/۴±۰/۳	۹۸/۶±۰/۲	۹۷/۶±۰/۴	۹۷/۶±۰/۵	۵۲/۲	Relief	نامتعادل (کل پایگاه)
۹۸/۴±۰/۳	۱/۶±۰/۴	۹۸/۹±۰/۳	۹۹/۰±۰/۲	۹۸/۴±۰/۴	۹۸/۴±۰/۴	۹۹/۹	NCA	نامتعادل (کل پایگاه)
۹۳/۴±۱/۱	۶/۶±۱/۱	۹۵/۴±۰/۷	۹۵/۸±۰/۶	۹۳/۴±۱/۱	۹۳/۵±۱/۱	۹۹/۳	PCA	نامتعادل (کل پایگاه)
۹۸/۰±۰/۸	۲/۰±۰/۸	۹۸/۷±۰/۶	۹۹/۰±۰/۴	۹۸/۰±۰/۸	۹۸/۱±۰/۸	۹۹/۷	NCA	متعادل شده
۹۴/۴±۱/۰	۵/۶±۱/۰	۹۶/۳±۰/۷	۹۷/۲±۰/۵	۹۴/۴±۱/۰	۹۴/۵±۱/۰	۹۹/۴	PCA	متعادل شده
۹۷/۷±۰/۷	۲/۳±۰/۷	۹۸/۵±۰/۵	۹۸/۹±۰/۴	۹۷/۷±۰/۷	۹۷/۷±۰/۷	۸۶	MRMR	متعادل شده

حالت برای مقایسه در بررسی‌های بعدی این تحقیق نیز به عنوان بخشی از روش پیشنهادی به کار گرفته شده است. جهت مقایسه‌ی روش پیشنهادی، انواع روش‌های طبقه‌بندی مرسوم نیز در تمام حالات به کار گرفته شده برای روش پیشنهادی پیاده‌سازی شده است. در این مقاله جهت جلوگیری از طولانی شدن بخش نتایج، از ارائه‌ی جزئیات این بررسی‌ها پرهیز شده و صرفاً ساختار انتخابی اعم از نوع نرمال‌سازی و متعادل‌سازی در دو حالت کل ویژگی‌ها و پس از کاهش بعد، برای روش‌های مقایسه‌ای اعمال شده است. تمام این پیاده‌سازی‌ها در نرم‌افزار متلب نسخه‌ی 2021b و روی سیستم کامپیوتری با مشخصات

هم‌چنین مقایسه‌ی نتایج جدول (۳) و بهترین نتیجه‌ی جدول (۲) نیز مهم است. در حقیقت با کاهش بعد ماتریس ویژگی به کمک روش NCA به تعدادی کم‌تر از یک‌سوم، حجم و زمان انجام محاسبات در هر دو مرحله‌ی آموزش و آزمایش کاهش می‌یابد و به طور هم‌زمان نتایج حاصل با بهترین نتیجه‌ی حاصل از الگوریتم پیشنهادی بدون کاهش بعد تفاوت چندانی ندارد. با توجه به انواع حالت‌های مقایسه شده‌ی موجود در جدول‌های (۲) و (۳) مشاهده می‌شود که بهترین نتایج به دست آمده از تصاویر پایگاه داده‌ی دوک در به کارگیری داده‌های متعادل شده با نرمال‌سازی در محدوده‌ی  $[0,1]$  به دست آمده است. این

همسایگی استفاده شده است. شبکه‌ی عصبی به کار گرفته شده یک شبکه‌ی پیش‌خور ۱۰ لایه بوده و جهت اعمال الگوریتم جنگل تصادفی از کدهای موجود در مقاله‌ی [۴۲] با عمق ۱۲، تعداد درخت ۱۰۰ و تعداد انشعاب ۳ استفاده شده است. نتایج این بخش در شکل (۱۰) و جدول (۵) ارائه شده است.

Intel-Core™i7-6700HQ CPU @2.6GHz و رم ۱۶ گیگابایت در سیستم عامل ویندوز ۱۰ انجام شده است. الگوریتم SVM چندکلاسه در نرم‌افزار متلب به صورت یک در برابر همه<sup>۱</sup> با الگوریتم آموزشی درختی پیاده‌سازی شده است. در طبقه‌بند k نزدیک‌ترین همسایه از فاصله‌ی اقلیدسی و محاسبه در ۵

جدول (۴) - ۵۰ ویژگی برتر در بهترین نتیجه‌ی مربوط به روش کاهش بعد NCA

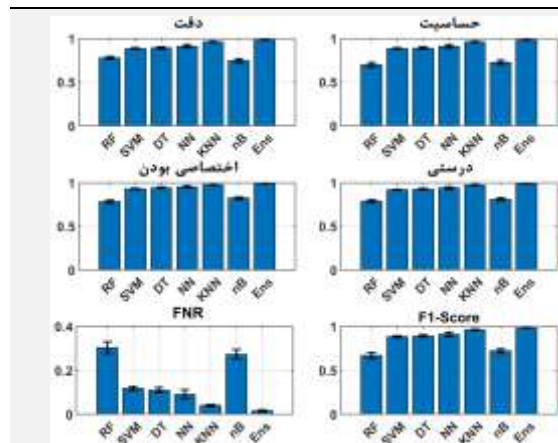
ردیف	نام ویژگی	ردیف	نام ویژگی
۱	بیشینه‌ی جز اول از EWT* خط ۲	۲۶	میانگین تقریب موجک فجرکروفکین ۴ خط ۱
۲	انترویی تی‌سالیس فاصله‌ی خطوط	۲۷	RMS جز دوم EWT خط ۱
۳	بیشینه‌ی جز اول از EWT خط ۱	۲۸	میانگین تقریب موجک سیملت ۴ خط ۱
۴	انترویی تی‌سالیس جز دوم VMD** خط ۲	۲۹	واریانس خط ۱
۵	بیشینه‌ی جز دوم از EWT خط ۲	۳۰	واریانس تقریب موجک سیملت ۴ خط ۱
۶	بیش‌ترین فاصله‌ی خطوط	۳۱	RMS خط ۲
۷	کم‌ترین فاصله‌ی خطوط	۳۲	RMS جز دوم EWT خط ۲
۸	کمینه‌ی جز دوم VMD خط ۱	۳۳	میانگین تقریب موجک فجرکروفکین ۴ خط ۲
۹	کمینه‌ی جز دوم EWT خط ۱	۳۴	میانگین تقریب موجک سیملت ۴ خط ۲
۱۰	انترویی تقریبی جز اول VMD خط ۲	۳۵	RMS جز دوم VMD خط ۲
۱۱	انترویی تی‌سالیس انحنای خط ۲	۳۶	میانگین تقریب موجک سیملت ۴ فاصله‌ی خطوط
۱۲	بیشینه‌ی جز دوم VMD خط ۲	۳۷	انترویی شنون فاصله‌ی خطوط
۱۳	کمینه‌ی جز دوم از EWT خط ۲	۳۸	انترویی نمونه‌ی خط ۲
۱۴	انترویی تی‌سالیس جز دوم VMD خط ۱	۳۹	انترویی تی‌سالیس خط ۱
۱۵	انترویی تقریبی جز اول EWT خط ۱	۴۰	انترویی تی‌سالیس جز دوم EWT خط ۱
۱۶	انترویی تقریبی فاصله‌ی خطوط	۴۱	RMS فاصله‌ی خطوط
۱۷	انترویی تی‌سالیس انحنای خط ۱	۴۲	میانگین تقریب موجک فجرکروفکین ۴ فاصله‌ی خطوط
۱۸	انترویی تقریبی جز دوم VMD خط ۲	۴۳	انترویی شنون خط ۱
۱۹	انترویی نمونه‌ی جز دوم VMD خط ۱	۴۴	انترویی شنون جز دوم EWT خط ۱
۲۰	انترویی تقریبی جز دوم EWT خط ۱	۴۵	واریانس جز دوم EWT خط ۱
۲۱	انترویی تقریبی جز اول EWT خط ۲	۴۶	کمینه‌ی خط ۱
۲۲	واریانس تقریب موجک فجرکروفکین ۴ خط ۱	۴۷	بیشینه‌ی خط ۱
۲۳	انترویی تقریبی جز دوم VMD خط ۱	۴۸	RMS جز اول EWT خط ۱
۲۴	انترویی تقریبی جز اول VMD خط ۱	۴۹	بیشینه‌ی جز دوم EWT خط ۱
۲۵	RMS خط ۱	۵۰	واریانس جز دوم EWT خط ۲

\* EWT: تبدیل موجک تجربی، \*\* VMD: تجزیه حالت وردشی

جدول (۵) - مقایسه‌ی حالات مختلف پیاده‌سازی روش پیشنهادی بدون کاهش بعد و داده‌های متعادل و نرمال‌سازی‌شده‌ی پایگاه داده‌ی دوک


روش	دقت	حساسیت	اختصاصی بودن	درستی	FNR	معیار FI
جنگل تصادفی	۸۱/۲±۲/۱	۷۷/۴±۲/۸	۸۸/۸±۱/۲	۸۴/۹±۱/۸	۲۲/۶±۲/۸	۷۷/۴±۲/۸
SVM	۸۶/۷±۱/۹	۸۶/۲±۱/۸	۹۳/۱±۰/۹	۹۰/۸±۱/۲	۱۳/۸±۱/۸	۸۶/۳±۱/۸
درخت تصمیم (DT)	۸۹/۱±۱/۴	۸۹/۰±۱/۳	۹۴/۵±۰/۷	۹۲/۶±۰/۹	۱۱/۰±۱/۳	۸۸/۹±۱/۳
شبکه عصبی پیش‌خور	۹۰/۶±۲/۱	۹۰/۵±۲/۱	۹۵/۲±۱/۰	۹۳/۶±۱/۴	۹/۵±۲/۱	۹۰/۵±۲/۱
K نزدیک‌ترین همسایه	۹۶/۲±۰/۷	۹۶/۱±۰/۸	۹۸/۱±۰/۴	۹۷/۴±۰/۵	۳/۹±۰/۸	۹۶/۱±۰/۸
بیز ساده	۷۰/۰±۲/۴	۶۲/۵±۲/۴	۸۱/۵±۱/۱	۷۵/۱±۱/۶	۳۷/۴±۲/۴	۶۰/۲±۲/۸
روش پیشنهادی	۹۸/۷±۰/۶	۹۸/۸±۰/۶	۹۹/۴±۰/۳	۹۹/۱±۰/۴	۱/۳±۰/۶	۹۸/۷±۰/۶

سه کلاس پایگاه داده‌ی دوک برای تمام روش‌های مقایسه‌ای و پیشنهادی نشان داده شده است. همان‌طور که مشاهده می‌شود روش پیشنهادی در تشخیص هر سه کلاس از عمل‌کرد بهتری برخوردار است. همچنین در سایر روش‌های مقایسه‌ای به ویژه جنگل تصادفی و بیز ساده عمل‌کرد ثابتی در کلاس‌های مختلف مشاهده نمی‌شود و برخی از کلاس‌ها نسبت به بقیه دارای نتایج تشخیص ضعیف‌تری هستند. نتایج مقایسه‌ی روش پیشنهادی با تحقیقاتی که در سال‌های اخیر روی پایگاه داده‌ی دوک انجام شده در جدول (۶) ارائه شده است. پیش‌تر به نقش مثبت متعادل‌سازی در بهبود نتایج اشاره شده است. با این حال در جدول (۶) اعداد مربوط به روش پیشنهادی در حالت به کارگیری داده‌های نامتعادل درج شده چون فرض شده که در روش‌های مقایسه‌ای از متعادل‌سازی استفاده نشده است. همان‌طور که مشاهده می‌شود در تمام موارد، روش پیشنهادی نتایج بهتری را به دست آورده است. در برخی از تحقیقات قبلی نتایج به صورت میانگین نیز ارائه شده [۷، ۱۳، ۱۹] که در جدول به همان صورت درج شده است. در پژوهش [۱۸] به دلیل عدم وجود نتیجه‌ی میانگین تمام دسته‌ها، نتایج به صورت جداگانه ارائه شده است. ضمناً در مواردی که مقدار معیار اعلام نشده، از خط‌تیره استفاده شده است.



شکل (۱۰) - نتایج معیارها در روش‌های پیشنهادی و مقایسه‌ای در پایگاه دوک (اعداد در محدوده‌ی صفر تا یک هستند)

بر اساس نتایج، روش پیشنهادی در مقایسه با سایر روش‌های مقایسه‌ای عمل‌کرد بهتری در تمام معیارهای ارزیابی دارد. در واقع روش پیشنهادی در شناسایی صحیح بیمار، شناسایی صحیح سالم و مجموع شناسایی بیمار و سالم عمل‌کرد خوبی دارد. به ویژه FNR روش پیشنهادی به طور قابل توجهی در مقایسه با سایر روش‌های مقایسه‌ای کمتر است. در واقع خطای عدم تشخیص بیمار در روش پیشنهادی بسیار کاهش یافته است. همچنین در شکل (۱۱) نتایج طبقه‌بندی چندکلاسه در



شکل (۱۱) - نتایج طبقه‌بندی سه کلاسه در روش پیشنهادی (ENS) و روش‌های مقایسه‌ای (پایگاه دوک)

جدول (۶) - مقایسه‌ی نتایج روش پیشنهادی با سایر مطالعات انجام شده روی پایگاه داده‌ی دوک با داده‌ی متعادل‌سازی نشده (بر حسب درصد)

مقاله	روش	کلاس‌ها	دقت	حساسیت	اختصاصیت	درستی	FNR	معیار F1
[۱۳]	LBP	نرمال و DME	-	۸۶/۶۷	۱۰۰	-	-	-
[۱۸]	CNN	سه کلاسه*	-	-	-	(AMD) ۷۶/۶ (DME) ۹۳/۳ (سالم) ۹۵/۳	-	-
[۷]	RF	سه کلاسه	-	-	-	۹۶/۷	-	-
[۱۹]	VGG-VAT	سه کلاسه	-	۹۴/۲	۹۷/۱	۹۴/۲	-	-
پیشنهادی	داده‌ی نامتعادل	سه کلاسه	۹۸/۰±۰/۶	۹۸/۰±۰/۶	۹۸/۷±۰/۳	۹۸/۶±۰/۴	۲/۰±۰/۶	۹۸/۰±۰/۶
پیشنهادی	داده‌ی نامتعادل و NCA	سه کلاسه	۹۸/۴	۹۸/۴	۹۹/۰	۹۸/۹	۱/۶	۹۸/۴

### ۳-۲- نتایج پایگاه داده‌ی کرمنی

برای ارزیابی بهتر، عمل کرد روش پیشنهادی و سایر روش‌های مقایسه‌ای روی پایگاه داده‌ی کرمنی نیز مورد بررسی قرار گرفته و نتایج در جدول‌های (۷) و (۸) ارائه شده است. با توجه به این که متعادل‌سازی داده‌ها در پایگاه داده‌ی کرمنی به دلیل عدم تعادل بسیار بالا (نمونه‌های دروسن ۸۶۱۶ و ۳۷۲۰۵ CNV) موجب حذف بخش عمده‌ای از داده‌ها می‌شود، در این بخش داده‌های اصلی و بدون اعمال متعادل‌سازی مورد استفاده قرار گرفته است. مشاهده می‌شود که روش پیشنهادی در تمام معیارها در مقایسه با سایر روش‌های مقایسه‌ای نتایج بهتری به دست آورده است. همچنین مشاهده می‌شود که تعداد بالای داده‌ها در این پایگاه داده موجب آموزش بهتر و کاهش قابل توجه انحراف معیار در تکرارهای مختلف شده است. به دلیل عمل کرد ضعیف روش جنگل تصادفی در برخی از کلاس‌ها که موجب صفر شدن TP و TN مربوطه شده، مقادیر دقت و F1 این روش غیرقابل محاسبه شده است. در جدول (۸) نیز نتایج تحقیقات اخیر که روی پایگاه داده‌ی کرمنی انجام شده، ارائه شده است. این پایگاه در سال ۲۰۱۸ ارائه شده و بر اساس

جست‌وجوهای انجام شده در این پژوهش، تحقیقی بر پایه‌ی روش‌های کلاسیک یادگیری ماشین و پایگاه داده‌ی کرمنی یافت نشده است. از این رو در جدول (۸) روش پیشنهادی با تحقیقات اخیر که بر پایه‌ی روش‌های یادگیری ژرف بودند مورد مقایسه قرار گرفته است. همان‌طور که مشاهده می‌شود روش به کار گرفته شده در این تحقیق که بر پایه‌ی روش‌های یادگیری ماشین کلاسیک می‌باشد در مقایسه با شبکه‌های قدرتمند ژرف، نتایج بهتری را در تمام معیارها به جز معیار حساسیت از خود نشان داده است. بیش‌ترین مقدار این معیار در جدول (۸) مربوط به روش کرمنی و هم‌کارانش [۱۷] بوده که بر اساس روش شبکه‌ی کانولوشنی ژرف حاصل شده است. با توجه به تفاوت بسیار کم حساسیت روش پیشنهادی و روش کرمنی و هم‌کارانش، به دلیل پیچیدگی کم روش پیشنهادی به نظر می‌رسد که می‌توان از این ضعف چشم‌پوشی کرد. باید توجه کرد که پایگاه داده‌ی کرمنی از دیدگاه تعداد داده‌ها بسیار نامتعادل است. همچنین در پایگاه مذکور تصاویر از تنوع بالایی از نظر زاویه‌ی تصویربرداری برخوردار بوده و به صورت شهودی دارای نویز بالاتری در مقایسه با پایگاه داده‌ی دوک می‌باشند.

**جدول (۷) - نتایج روش‌های مقایسه‌ای و روش پیشنهادی بدون کاهش بعد و داده‌های نامتعادل و نرمال‌سازی شده از پایگاه داده‌ی کرمنی**

(بر حسب درصد)

روش	دقت	حساسیت	اختصاصی بودن	درستی	FNR	معیار FI
جنگل تصادفی	-	۴۶/۱±۰/۰	۸۲/۰±۰/۰۴	۷۳/۱±۰/۰۸	۵۳/۹±۰/۰۲	-
SVM	۹۰/۵±۰/۰۴	۹۰/۱±۰/۰۵	۹۶/۷±۰/۰۲	۹۵/۰±۰/۰۲	۹/۹±۰/۰۵	۸۹/۹±۰/۰۵
درخت تصمیم (DT)	۸۶/۶±۰/۰۶	۸۵/۹±۰/۰۵	۹۵/۳±۰/۰۲	۹۳/۰±۰/۰۲	۱۴/۱±۰/۰۵	۸۵/۷±۰/۰۵
شبکه‌ی عصبی پیش‌خور	۶۰/۳±۱/۹۹	۵۹/۳±۲/۴	۸۶/۵±۰/۰۸	۷۹/۷±۱/۲	۴۰/۷±۲/۴	۵۹/۲±۲/۲
K نزدیک‌ترین همسایه	۸۱/۸±۰/۰۸	۷۸/۷±۰/۰۵	۹۲/۹±۰/۰۲	۸۹/۴±۰/۰۳	۲۱/۳±۰/۰۵	۷۸/۰±۰/۰۵
بیز ساده	۶۶/۱±۰/۰۰	۶۳/۰±۰/۰۰	۸۷/۶±۰/۰۰	۸۱/۵±۰/۰۰	۳۷/۰±۰/۰۰	۶۱/۸±۰/۰۰
پیشنهادی	۹۶/۸±۰/۰۲	۹۶/۷±۰/۰۲	۹۸/۹±۰/۰۱	۹۸/۴±۰/۰۱	۳/۲±۰/۰۲	۹۶/۷±۰/۰۲

**جدول (۸) - مقایسه‌ی نتایج روش پیشنهادی با سایر مطالعات انجام شده روی پایگاه داده‌ی کرمنی**

مقاله	روش	کلاس‌ها	دقت	حساسیت	اختصاصیت	درستی	FNR	معیار FI
[۱۷]	CNN	چهار کلاسه*	-	۹۷/۸	۹۷/۴	۹۶/۶	۶/۶	-
[۳]	CNN	چهار کلاسه	-	-	-	۹۵/۳	-	-
[۴۳]	IFCNN	DRUSEN CNV DME سالم	-	۷۶/۸ ۸۷/۹ ۸۱/۹ ۹۲/۲	۹۴/۹ ۹۶ ۹۶/۳ ۹۶	میانگین ۸۷/۳	-	-
[۱۹]	VGG-VAT	چهار کلاسه	-	۹۳/۶	۹۷/۹	۹۳/۶	-	-
پیشنهادی	داده‌ی نامتعادل	چهار کلاسه	۹۶/۸	۹۷/۰	۹۸/۹	۹۸/۴	۳/۲	۹۶/۷

\*AMD, CNV, DME و سالم، کلبه اعداد در این جدول بر حسب درصد بیان شده است.

### ۴- نتیجه‌گیری

در این تحقیق الگوریتمی جدید و خودکار جهت پردازش و طبقه‌بندی تصاویر SD-OCT ارائه شده است. هدف اصلی این

تحقیق ارائه‌ی روشی جدید با ویژگی‌های موثر برای تشخیص دقیق‌تر بیماری‌های شبکه‌ی است. در این راستا در انتخاب ویژگی‌ها از دیدگاه پزشکان متخصص چشم الهام گرفته شده



پیچیده و زمان‌بری را در بر داشته و در مرحله‌ی آزمون نیز با حجم بالای محاسبات مواجه هستند، نتایج بهتری را در تمام معیارهای مقایسه‌ای به دست آورده است. به ویژه مقادیر FNR یا خطای تشخیص بیمار در روش پیشنهادی در مقایسه با روش‌های مقایسه‌ای کاهش چشم‌گیری داشته است.

یکی دیگر از خروجی‌های این تحقیق، طراحی نرم‌افزار کاربردی با GUI برای پردازش و طبقه‌بندی تصاویر SD-OCT در نرم‌افزار متلب با نام SiOCT است. در این نرم‌افزار کاربردی، امکان استخراج خطوط، استخراج انواع ویژگی‌ها و به کارگیری روش‌های مختلف طبقه‌بندی چندکلاسه به همراه امکان تعیین روش‌های نرمال‌سازی، متعادل‌سازی و انتخاب ویژگی فراهم شده است. این ابزار از طریق گیت‌هاب در دسترس علاقه‌مندان قرار داده شده است.

در کارهای آینده و برای تسهیل تحلیل برخط و خودکار تصاویر در محیط‌های درمانی، نرم‌افزار SiOCT جهت نصب روی سیستم عامل ویندوز و یا به صورت یک افزونه در سامانه‌های تصویربرداری بازطراحی خواهد شد. هم‌چنین از آن‌جا که در این تحقیق نتایج مطلوبی در تشخیص لایه‌های مهم آناتومیکی در تصاویر دو بعدی به دست آمده است، نتایج مذکور در کارهای آینده برای تشخیص سطوح لایه‌ها در تصاویر حجمی SD-OCT به کار گرفته خواهد شد.

## ۵- مراجع

- [1] M. P. Gupta, A. A. Herzlich, T. Sauer, and C.-C. Chan, "Retinal anatomy and pathology," *Retinal Pharmacotherapeutics*, vol. 55, pp. 7-17, 2016.
- [2] W. H. Organization, "World report on vision," 2019.
- [3] A. M. Alqudah, "AOCT-NET: a convolutional network automated classification of multiclass retinal diseases using spectral-domain optical coherence tomography images," *Medical & biological engineering & computing*, vol. 58, no. 1, pp. 41-53, 2020.
- [4] A. Alqudah and A. M. Alqudah, "Artificial Intelligence Hybrid System for Enhancing Retinal Diseases Classification Using Automated Deep Features Extracted from OCT Images," *International Journal of Intelligent Systems and Applications in Engineering*, vol. 9, no. 3, pp. 91-100, 2021.
- [5] فیضی، محدثه، پاکروان، محمد، "آزمون‌های تشخیصی در نوروفتالمولوژی." *مجله چشم‌پزشکی*، vol. 21, no. 3, pp. 285-294, 2016.
- [6] P. P. Srinivasan et al., "Fully automated detection of diabetic macular edema and dry age-related macular degeneration from optical coherence tomography images," *Biomedical*

است. پزشکان در تشخیص بیماری‌های شبکیه از بررسی شکل هندسی و فواصل بین لایه‌های شبکیه در تصاویر SD-OCT استفاده می‌کنند. از این رو پس از پیش‌پردازش تصاویر، خطوط دو لایه‌ی مهم RNFL و IS/OS آشکارسازی شده است. در این راستا و در الگوریتم پیشنهادی پس از انجام مجموعه‌ای از اقدامات و اعمال فیلترهای میانه و گوسی، تصویر برای پردازش اصلی آماده‌سازی شده است. سپس با به کارگیری روش تشخیص رگ فرنگی که بر تصویر گرادیان اعمال شده، خطوط مطلوب تشخیص داده شده است. در ادامه با استخراج ویژگی‌های خطی و غیرخطی از خطوط استخراج شده، تجزیه‌ی حالت وردشی (VMD) و تبدیل موجک تجربی (EWT) خطوط، تفاضل خطوط، انحنای خطوط و تفاضل انحنای خطوط، ماتریس ویژگی‌های پیشنهادی تحقیق تشکیل شده است. سپس با به کارگیری الگوریتم درخت تصمیم ترکیبی، روش موثر برای طبقه‌بندی چندکلاسه‌ی پایگاه داده‌ی دانشگاه دوک (سه کلاسه) و پایگاه داده‌ی کرمی (چهار کلاسه) ارائه شده است. هم‌چنین شرایط گوناگونی مانند انواع نرمال‌سازی داده‌ها، به کارگیری داده‌های متعادل و انواع روش‌های انتخاب ویژگی نیز مورد بررسی قرار گرفته است. هم‌چنین روش‌های متعدد طبقه‌بندی مقایسه‌ای مانند درخت تصمیم،  $k$  نزدیک‌ترین همسایه، جنگل تصادفی، SVM، الگوریتم بیز ساده و شبکه‌ی عصبی پیش‌خور نیز پیاده‌سازی شده و نتایج توسط محاسبه‌ی معیارهای متعدد مورد بررسی و ارزیابی قرار گرفته است. هم‌چنین نتایج روش پیشنهادی با سایر تحقیقاتی که در این زمینه و روی پایگاه‌های داده‌ی دوک و کرمی انجام شده مقایسه شده است. از مقایسه‌ی نتایج می‌توان به این جمع‌بندی رسید که نرمال‌سازی ماتریس ویژگی‌ها در محدوده‌ی  $[0,1]$  در مقایسه با حالت بدون نرمال‌سازی و نرمال‌سازی نمره‌ی  $z$  نتایج بهتری را ایجاد می‌کند. هم‌چنین به کارگیری داده‌های متعادل در پایگاه داده‌ی دوک در هر کلاس نتایج بهتری از نظر معیارهای مقایسه‌ای ایجاد می‌نماید. علاوه بر مقایسه‌های اشاره شده در بالا، روش‌های انتخاب ویژگی MRMR، PCA، NCA، ReliefF و Chi-2 نیز اعمال شده است. با مقایسه‌ی نتایج انتخاب ۵۰ ویژگی برتر توسط هر یک از این روش‌ها، مشخص شده که در داده‌های این تحقیق روش NCA بهترین پاسخ را به دست آورده است.

بر اساس نتایج به دست آمده، روش پیشنهادی این تحقیق که جزو روش‌های یادگیری ماشین کلاسیک قرار می‌گیرد، از روش‌های به کار رفته در سایر تحقیقات اخیر که عموماً بر پایه‌ی الگوریتم‌های یادگیری ژرف بوده و مسلماً مراحل آموزش بسیار

- deep learning," *Cell*, vol. 172, no. 5, pp. 1122-1131. e9, 2018.
- [18] Y. Rong et al., "Surrogate-assisted retinal OCT image classification based on convolutional neural networks," *IEEE journal of biomedical and health informatics*, vol. 23, no. 1, pp. 253-263, 2018.
- [19] Y. Luo, Q. Xu, R. Jin, M. Wu, and L. Liu, "Automatic detection of retinopathy with optical coherence tomography images via a semi-supervised deep learning method," *Biomedical Optics Express*, vol. 12, no. 5, pp. 2684-2702, 2021.
- [20] A. F. Frangi, W. J. Niessen, K. L. Vincken, and M. A. Viergever, "Multiscale vessel enhancement filtering," in *International conference on medical image computing and computer-assisted intervention*, 1998, pp. 130-137: Springer.
- [21] Mathworks. Edge-aware local contrast manipulation of images. Available: <https://www.mathworks.com/help/images/ref/localcontrast.html>
- [22] C. E. Shannon, "A mathematical theory of communication," *The Bell system technical journal*, vol. 27, no. 3, pp. 379-423, 1948.
- [23] J. S. Richman and J. R. Moorman, "Physiological time-series analysis using approximate entropy and sample entropy," *American Journal of Physiology-Heart and Circulatory Physiology*, 2000.
- [24] A. Rényi, *Probability theory*. Courier Corporation, 2007.
- [25] C. Tsallis, R. Mendes, and A. R. Plastino, "The role of constraints within generalized nonextensive statistics," *Physica A: Statistical Mechanics and its Applications*, vol. 261, no. 3-4, pp. 534-554, 1998.
- [26] S. M. Pincus, "Approximate entropy as a measure of system complexity," *Proceedings of the National Academy of Sciences*, vol. 88, no. 6, pp. 2297-2301, 1991.
- [27] J. W. Harris and H. Stöcker, *Handbook of mathematics and computational science*. Springer Science & Business Media, 1998.
- [28] M. Nielsen, "On the construction and frequency localization of finite orthogonal quadrature filters," *Journal of Approximation Theory*, vol. 108, no. 1, pp. 36-52, 2001.
- [29] Y. Song and P. Liò, "A new approach for epileptic seizure detection: sample entropy based feature extraction and extreme learning machine," *Journal of Biomedical Science and Engineering*, vol. 3, no. 06, p. 556, 2010.
- [30] M. Borowska, "Entropy-based algorithms in the analysis of biomedical signals," *Studies in Logic, Grammar and Rhetoric*, vol. 43, no. 1, pp. 21-32, 2015.
- [31] C. Ding and H. Peng, "Minimum redundancy feature selection from microarray gene expression data," *Journal of bioinformatics and computational biology*, vol. 3, no. 02, pp. 185-205, 2005.
- optics express, vol. 5, no. 10, pp. 3568-3577, 2014.
- [7] M. A. Hussain et al., "Classification of healthy and diseased retina using SD-OCT imaging and Random Forest algorithm," *PloS one*, vol. 13, no. 6, p. e0198281, 2018.
- [8] A. Herzog, K. L. Boyer, and C. Roberts, "Extracting the optic disk endpoints in optical coherence tomography data," in *2005 Seventh IEEE Workshops on Applications of Computer Vision (WACV/MOTION'05)-Volume 1, 2005*, vol. 1, pp. 263-268: IEEE.
- [9] R. Bernardes, C. Maduro, P. Serranho, A. Araújo, S. Barbeiro, and J. Cunha-Vaz, "Improved adaptive complex diffusion despeckling filter," *Optics express*, vol. 18, no. 23, pp. 24048-24059, 2010.
- [10] A. Usha, N. Shajil, and M. Sasikala, "Automatic Anisotropic Diffusion Filtering and Graph-search Segmentation of Macular Spectral-domain Optical Coherence Tomographic (SD-OCT) Images," *Current Medical Imaging*, vol. 15, no. 3, pp. 308-318, 2019.
- [۱۱] س. دانشور، "تشخیص ضایعات قرمز بیماری رتینوپاتی با استفاده از موجک مورلت در تصاویر رنگی شبکه،" *کارشناسی ارشد، وزارت علوم، تحقیقات و فناوری - دانشگاه فردوسی مشهد - دانشکده مهندسی، ۱۳۹۱*.
- [۱۲] م. تاجی and س. آیت، "تشخیص بیماری رتینوپاتی دیابت با استفاده از پردازش تصاویر فوندوس شبکه و تکنیک‌های مورفولوژیک،" (in persian), *مجله انفورماتیک سلامت و زیست پزشکی*, vol. 6, no. 3, pp. 218-230, 1398.
- [13] G. Lemaître, M. Rastgoo, J. Massich, S. Sankar, F. Mériaudeau, and D. Sidibé, "Classification of SD-OCT Volumes with LBP: Application to DME Detection," presented at the *Ophthalmic Medical Image Analysis Workshop (OMIA), Medical Image Computing and Computer Assisted Interventions (MICCAI) 2015, Munich, Germany, 2015-10-05, 2015*. Available: <https://hal-univ-bourgogne.archives-ouvertes.fr/hal-01235888>
- [14] D. Sidibe et al., "An anomaly detection approach for the identification of DME patients using spectral domain optical coherence tomography images," *Computer methods and programs in biomedicine*, vol. 139, pp. 109-117, 2017.
- [15] B. S. Gerendas et al., "Computational image analysis for prognosis determination in DME," *Vision research*, vol. 139, pp. 204-210, 2017.
- [16] D. Kermany, K. Zhang, and M. Goldbaum, "Labeled optical coherence tomography (oct) and chest X-ray images for classification," *Mendeley data*, vol. 2, no. 2, 2018.
- [17] D. S. Kermany et al., "Identifying medical diagnoses and treatable diseases by image-based



- [39] H.-D. Li, M. Kallergi, L. P. Clarke, V. K. Jain, and R. A. Clark, "Markov random field for tumor detection in digital mammography," *IEEE transactions on medical imaging*, vol. 14, no. 3, pp. 565-576, 1995.
- [40] M. Hossin and M. N. Sulaiman, "A review on evaluation metrics for data classification evaluations," *International journal of data mining & knowledge management process*, vol. 5, no. 2, p. 1, 2015.
- [41] M. Fatourehchi, R. K. Ward, S. G. Mason, J. Huggins, A. Schloegl, and G. E. Birch, "Comparison of evaluation metrics in classification applications with imbalanced datasets," in *2008 seventh international conference on machine learning and applications*, 2008, pp. 777-782: IEEE.
- [42] (11/10/2021). Karpathy Random Forest Matlab. Available: <https://github.com/karpathy/Random-Forest-Matlab/blob/master/lib/>
- [43] L. Fang, Y. Jin, L. Huang, S. Guo, G. Zhao, and X. Chen, "Iterative fusion convolutional neural networks for classification of optical coherence tomography images," *Journal of Visual Communication and Image Representation*, vol. 59, pp. 327-333, 2019.
- [32] R. J. Tallarida and R. B. Murray, "Chi-square test," in *Manual of pharmacologic calculations*: Springer, 1987, pp. 140-142.
- [33] W. Yang, K. Wang, and W. Zuo, "Neighborhood component feature selection for high-dimensional data," *J. Comput.*, vol. 7, no. 1, pp. 161-168, 2012.
- [34] M. Robnik-Šikonja and I. Kononenko, "An adaptation of Relief for attribute estimation in regression," in *Machine Learning: Proceedings of the Fourteenth International Conference (ICML'97)*, 1997, vol. 5, pp. 296-304.
- [35] I. T. Jolliffe and J. Cadima, "Principal component analysis: a review and recent developments," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 374, no. 2065, p. 20150202, 2016.
- [36] T. G. Dietterich, "Ensemble learning," *The handbook of brain theory and neural networks*, vol. 2, no. 1, pp. 110-125, 2002.
- [37] D. Che, Q. Liu, K. Rasheed, and X. Tao, "Decision tree and ensemble learning algorithms with their applications in bioinformatics," *Software tools and algorithms for biological systems*, pp. 191-199, 2011.
- [38] L. Breiman, "Bagging predictors," *Machine learning*, vol. 24, no. 2, pp. 123-140, 1996.