

A New Method for Automatic Diagnosis of Age-Related Macular Degeneration using Optical Coherence Tomography Images

Babaoghli, Amir¹ / Soltanizadeh, Hadi^{2*}

¹ - M.Sc. Student, Telecommunications Department, Electrical and Computer Engineering Faculty, Semnan University, Semnan, Iran

² - Assistant Professor, Electronic Department, Electrical and Computer Engineering Faculty, Semnan University, Semnan, Iran

ARTICLE INFO

DOI: 10.22041/IJBME.2019.105465.1462

Received: 20 March 2019

Revised: 19/6/2019-9/8/2019

Accepted: 8 September 2019

KEYWORDS

Image Processing
Optical Coherence Tomography
Age Related Macular Degeneration
Histogram of Oriented Gradients
Principal Component Analysis
Ensemble Classification
Adaboost


ABSTRACT

Diseases associated with the retina and macula of the eye, causing permanent loss of vision or a great deal of loss of vision in people, leads to a decrease in the quality of life and a lot of problems in daily life. For this reason, the timely and correct identification of these diseases and disorders has become important. The optical coherence tomography imaging method provides high precision in imaging and good information about the depth of the retina. This imaging technique is a great help in the accurate identification of macular-related diseases. Age-related macular degeneration is one of the most common retinal diseases. The purpose of this study is to design and implement a system that is reliable, fast and can detect the age-related macular degeneration by using optical coherence tomography image processing accurately and quickly. In these studies, histograms of orientational gradients and principal component analysis for extraction of features and AdaBoost ensemble classification method have been used to classify the data. The database used includes 269 patients and 115 healthy people. All three indicators of accuracy, sensitivity and specificity of the implemented system were measured at 100%.

***Corresponding Author**

Address	Electronic Department, Electrical and Computer Engineering Faculty, Semnan University, Semnan, Iran		
Postal Code	35131-19111	Tel	+98-23-31533995
E-Mail	h_soltanizadeh@semnan.ac.ir		
		Fax	+98-23-31533995





ارائه‌ی روشی جدید برای تشخیص خودکار بیماری دژنراسیون وابسته به سن ماکولا با استفاده از تصاویر مقطع‌نگاری همدوسی اپتیکی

بابااوغلی، امیر^۱ / سلطانی‌زاده، هادی^{۲*}

^۱ - دانشجوی کارشناسی ارشد مهندسی برق، گروه مخابرات، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران

^۲ - استادیار، گروه الکترونیک، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/IJBME.2019.105465.1462

پذیرش: ۱۷ شهریور ۱۳۹۸

بازنگری: ۱۳۹۸/۵/۱۸-۱۳۹۸/۳/۲۹

ثبت در سامانه: ۲۹ اسفند ۱۳۹۷

چکیده

واژه‌های کلیدی

بیماری‌های مرتبط با شبکه‌ی و ماکولای چشم باعث از دست رفتن دائمی بینایی یا کاهش بسیار زیاد دید در افراد شده و موجب پایین آمدن کیفیت زندگی و ایجاد مشکلات فراوان در زندگی روزمره‌ی بیماران می‌شود. از این‌رو شناسایی به هنگام و درست این بیماری‌ها و اختلالات از اهمیت بسیار زیادی برخوردار است. روش تصویربرداری مقطع‌نگاری همدوسی اپتیکی دقت بالایی در تصویربرداری داشته و هم‌چنین اطلاعات عمقی از شبکه‌ی ارائه می‌دهد. این روش تصویربرداری کمک بسیار زیادی به شناسایی دقیق بیماری‌های مرتبط با ماکولا کرده است. یکی از شایع‌ترین بیماری‌های شبکه‌ی چشم، بیماری دژنراسیون وابسته به سن ماکولا است. هدف از انجام این پژوهش طراحی و پیاده‌سازی سیستمی قابل اعتماد و سریع است که بتواند بیماری دژنراسیون وابسته به سن ماکولا را با استفاده از پردازش تصاویر مقطع‌نگاری همدوسی اپتیکی به خوبی و با دقت و سرعت بالا شناسایی کند. در این مطالعه از روش‌های هیستوگرام گرادیان‌های جهت‌دار و تحلیل مولفه‌ی اصلی برای استخراج ویژگی‌ها و از روش طبقه‌بندی گروهی AdaBoost جهت طبقه‌بندی داده‌ها استفاده شده است. پایگاه داده‌ی مورد استفاده در این مقاله شامل ۲۶۹ فرد بیمار و ۱۱۵ فرد سالم است. هر سه شاخص دقت، حساسیت و خاصیت سیستم پیاده‌سازی شده برابر با ۱۰۰٪ اندازه‌گیری شده است.

پردازش تصویر

مقطع‌نگاری همدوسی اپتیکی

دژنراسیون وابسته به سن ماکولا

هیستوگرام گرادیان‌های

جهت‌دار

تحلیل مولفه‌ی اصلی

طبقه‌بندی گروهی

*نویسنده‌ی مسئول

نشانی گروه الکترونیک، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران

تلفن +۹۸-۲۳-۳۱۵۳۳۹۹۵

۳۵۱۳۱-۱۹۱۱۱

دورنگار +۹۸-۲۳-۳۱۵۳۳۹۹۵

h_soltanizadeh@semnan.ac.ir

کد پستی

پست الکترونیک

۱- مقدمه

تصویربرداری در پزشکی اهمیت زیادی داشته و اساس تشخیص بسیاری از بیماری‌ها است. روش‌های تصویربرداری را می‌توان به دو بخش تهاجمی و غیرتهاجمی دسته‌بندی کرد. روش‌های تهاجمی می‌تواند برای بیمار عوارضی داشته و تغییرات نامطلوبی را در بدن بیمار ایجاد کند. روش‌های غیرتهاجمی بدون ایجاد تغییر در بدن بیمار تصویربرداری را انجام می‌دهند که از آن جمله می‌توان به روش‌های سونوگرافی، مقطع‌نگاری همدوسی اپتیکی^۱ و فوندوس^۲ اشاره کرد [۱]. در چشم‌پزشکی دو روش فوندوس و مقطع‌نگاری همدوسی اپتیکی با توجه به غیرتهاجمی بودن از اهمیت زیادی برخوردار بوده و بیش‌ترین کاربرد را در این حوزه دارند. روش تصویربرداری مقطع‌نگاری همدوسی اپتیکی، برای اولین بار در سال ۱۹۹۱ میلادی توسط هانگ و هم‌کارانش معرفی شده است [۲]. این روش با توجه به تصویربرداری عمقی و سه‌بعدی و دقت بالای تصاویر ارائه شده، نسبت به روش تصویربرداری فوندوس برتری دارد. از این روش تصویربرداری عمدتاً برای تشخیص و ارزیابی بیماری‌های شبکیه و قسمت ماکولای^۳ چشم استفاده می‌شود. امروزه شناسایی بیماری‌های مرتبط با ماکولای چشم از اهمیت زیادی برخوردار است زیرا صدمات ناشی از این بیماری‌ها جبران‌ناپذیر بوده و زندگی فرد را دچار مشکل می‌کند [۳]. از بیماری‌های شبکیه‌ی چشم می‌توان به سوراخ ماکولا، تورم دیابتیک ماکولا، گلوکوما و دژنراسیون وابسته به سن ماکولا^۴ اشاره کرد [۴].

با توسعه‌ی الگوریتم‌ها و افزایش توان پردازش اطلاعات پردازنده‌های رایانه‌ای، استفاده از الگوریتم‌های توسعه‌یافته در کاربردهای مختلف پزشکی به سرعت در حال گسترش است. پردازش خودکار و نیمه‌خودکار تصاویر مختلف پزشکی مانند تصاویر مقطع‌نگاری همدوسی اپتیکی، یکی از متداول‌ترین کاربردهای این الگوریتم‌ها است [۵، ۶]. امروزه تفسیر تصاویر مقطع‌نگاری همدوسی اپتیکی اغلب بر توسعه‌ی روش‌های قطعه‌بندی لایه‌ی اتوماتیک متمرکز شده است [۷، ۸، ۹]. بیماری دژنراسیون وابسته به سن ماکولا بیش‌ترین سهم را در از دست دادن بینایی افراد بزرگ‌سال دارد. از این‌رو شناسایی سریع، دقیق و قابل اطمینان این بیماری بسیار حائز اهمیت است. در این پژوهش یک سیستم قابل اعتماد، دقیق و سریع

بر اساس پردازش تصاویر مقطع‌نگاری همدوسی اپتیکی جهت شناسایی بیماری دژنراسیون وابسته به سن ماکولا طراحی و ارائه شده است. در پژوهش‌های پیشین تلاش‌های ارزش‌مندی برای شناسایی بیماری دژنراسیون وابسته به سن ماکولا با استفاده از تصاویر مقطع‌نگاری همدوسی اپتیکی صورت گرفته که در جدول (۱) به اختصار به آن‌ها اشاره شده است. پژوهش‌های انجام شده را می‌توان از منظر روش طبقه‌بندی به دو دسته‌ی طبقه‌بندی با روش‌های آماری-ریاضیاتی و آموزش عمیق یا شبکه‌های عصبی^۵ تقسیم کرد. در جدول (۱) روش‌های ۱ تا ۷ از دسته‌ی اول و بقیه از دسته‌ی دوم هستند.

جدول (۱) - بررسی مختصر پژوهش‌های پیشین

مرجع	روش	حساسیت	دقت	AUC ^۶
[۱۰]	Spatial Pyramid + HOG + SVM	۸۹/۱	۸۶/۶۸	۹۶/۳
[۱۱]	PCA + Random Forest	-	-	۹۸/۴
[۱۲]	HOG + SVM	۹۶/۸	۹۴/۴	۹۲/۱
[۱۳]	Spatial Pyramid + LCP + SVM	۹۸	۹۸	۹۸/۸
[۱۴]	LBP + HOG + Bayesian Classifier	۹۲/۴	۹۱/۴	۹۰/۵
[۱۵]	Spatial Pyramid + LPB + PCA + SVM	-	-	۹۳/۸
[۱۶]	Statistical Scores + GLM	-	-	۹۹/۱
[۱۷]	LBP + CNN ^۷	۸۷	-	-
[۱۸]	Spatial Pyramid + CNN	۹۹/۳۶	-	۹۹/۸
[۱۹]	Deep Neural Network	۸۳/۸۲	۹۳/۴۵	۹۶/۴
[۲۰]	RetiNet CNN	-	-	۹۹/۷

سیستم اول از روش‌های هرم فضایی^۸، هیستوگرام گرادیان‌های جهت‌دار^۹ و ماشین بردار پشتیبان^{۱۰} خطی استفاده کرده و متکی بر گام کاهش نویز است. سیستم دوم از تحلیل مولفه‌ی اصلی^{۱۱} و طبقه‌بند جنگل تصادفی^{۱۲} استفاده کرده و نکته‌ی مثبت و مهم آن عدم نیاز به قطعه‌بندی دقیق لایه‌های شبکیه است. سیستم سوم طبقه‌بندی را با بهره‌گیری از روش‌های استخراج منطقه‌ی مطلوب^{۱۳}، هیستوگرام گرادیان‌های جهت‌دار و ماشین بردار پشتیبان انجام می‌دهد. سیستم چهارم از

^۸ Spatial Pyramid

^۹ Histogram of Oriented Gradients (HOG)

^{۱۰} Support Vector Machine (SVM)

^{۱۱} Principal Component Analysis (PCA)

^{۱۲} Random Forest

^{۱۳} Region of Interest (ROI)

^۱ Optical Coherence Tomography (OCT)

^۲ Fundus

^۳ Macula


^۴ Age-Related Macular Degeneration (AMD)

^۵ Neural Networks

^۶ Area Under the Curve (AUC)

^۷ Convolutional Neural Network

است. هدف از انجام پیش‌پردازش، کاهش نویز تصاویر، اصلاح انحنای شبکه در تصاویر و ایجاد تصاویر مناسب برای مرحله‌ی استخراج ویژگی‌ها است. در بخش دوم ویژگی‌های مناسب در چهار گام هرم فضایی، لبه‌یابی^۴، هیستوگرام گرادیان‌های جهت‌دار و تحلیل مولفه‌ی اصلی، استخراج شده و در اختیار بخش سوم (طبقه‌بندی کننده) قرار می‌گیرد. طبقه‌بند مورد استفاده در این پژوهش طبقه‌بند گروهی AdaBoost می‌باشد.



۲-۱-۲- پیش‌پردازش

تصاویر مورد استفاده در این پژوهش با توجه به ماهیت روش تصویربرداری مقطع‌نگاری همدوسی اپتیکی به به‌سازی و بالا بردن کیفیت نیاز دارند. هدف بخش پیش‌پردازش، آماده‌سازی تصاویر خام برای بخش استخراج ویژگی‌ها و استخراج ویژگی‌های با کیفیت از روی تصاویر است. این بخش شامل سه قسمت کاهش نویز، اصلاح انحنای شبکه و برش تصویر است.

۲-۱-۱-۲- کاهش نویز

گام اول از بخش پیش‌پردازش، کاهش نویز تصاویر است. تصاویر به دست آمده از روش تصویربرداری مقطع‌نگاری همدوسی اپتیکی به شدت دارای نویز بوده و لازم است تا عملیات کاهش نویز روی آن‌ها انجام شود. ماهیت نویز تصاویر مقطع‌نگاری

روش‌های هرم فضایی، الگوی پیکربندی خطی^۱ و ماشین بردار پشتیبان استفاده کرده و نیازی به تقسیم‌بندی لایه‌های شبکه در آن نیست. سیستم پنجم کلاس‌بندی داده‌ها را با بهره‌گیری از روش‌های الگوهای باینری محلی^۲، هیستوگرام گرادیان‌های جهت‌دار و طبقه‌بند بیز انجام داده و متکی بر روش کاهش نویز است. سیستم ششم با استفاده از روش‌های هرم فضایی، الگوهای باینری محلی، هیستوگرام گرادیان‌های جهت‌دار و طبقه‌بند ماشین بردار پشتیبان با هسته‌ی تابع پایه‌ی شعاعی، بیماری را شناسایی می‌کند. در سیستم هفتم از ویژگی‌های آماری مانند ضخامت لایه‌های مختلف و روش مدل خطی تعمیم‌یافته^۳ استفاده شده است. سیستم‌های هشتم تا یازدهم جزء دسته‌ی دوم بوده و از شبکه‌های عصبی کانولوشنی جهت شناسایی بیماری استفاده می‌کنند. در این سیستم‌ها ویژگی‌ها با استفاده از فیلترهای مختلف استخراج شده و طبقه‌بندی انجام می‌شود. این سیستم‌ها برای ارائه‌ی عمل‌کرد قابل قبول به پایگاه داده‌ی بزرگ نیاز دارند که به سهولت در دسترس نیست.

روش‌های دسته‌ی اول سریع بوده، پیچیدگی کمی داشته و برای پردازش به سیستم‌های رایانه‌ای قدرتمند نیاز ندارند اما نتایج آن‌ها به خوبی نتایج روش‌های دسته‌ی دوم نیست. روش‌های دسته‌ی دوم نتایج بسیار خوبی را ارائه داده اما پیچیدگی بالا و عمل‌کرد کندی داشته و به سیستم‌های رایانه‌ای قدرتمندی برای پردازش نیاز دارند. سیستم پیشنهادی این مقاله بر اساس روش طبقه‌بندی آماری-ریاضیاتی طبقه‌بند گروهی AdaBoost طراحی و پیاده‌سازی شده و عمل‌کرد بسیار خوبی در جهت تامین هدف این مطالعات ارائه کرده است.

در بخش ۲ روش پیشنهادی این مقاله شرح داده شده، در بخش ۳ نتایج این پژوهش، عوامل موثر بر نتایج، مقایسه‌ی نتایج با پژوهش‌های پیشین و پایگاه داده‌ی مورد مطالعه ارائه شده و در بخش ۴ به نتیجه‌گیری پرداخته شده است.

۲- روش پیشنهادی

اساس روش پیشنهادی این پژوهش، پردازش تصاویر مقطع‌نگاری همدوسی اپتیکی مربوط به بیماری دژنراسیون وابسته به سن ماکولا است. دیاگرام فرایند پردازش تصاویر به منظور شناسایی بیماری دژنراسیون وابسته به سن ماکولا در شکل (۱) نشان داده شده است. همان‌طور که مشاهده می‌شود این فرایند از سه بخش عمده‌ی پیش‌پردازش، استخراج ویژگی‌ها و طبقه‌بندی ویژگی‌های استخراج شده تشکیل شده

^۱ Generalized Linear Model (GLM)

^۴ Edge Detection

^۱ Linear Configuration Pattern (LCP)

^۲ Local Binary Patterns (LBP)


پس از آموزش دیکشنری می‌توان نویز تصویر هدف را کاهش داد. کاهش نویز تصاویر در دو گام انتخاب زیردیکشنری مناسب برای هر قطعه‌ی تصویر هدف و محاسبه‌ی قطعات حذف نویز شده انجام می‌شود. برای انتخاب زیردیکشنری مناسب (D_i^A) از رابطه‌ی (۱) استفاده می‌شود.

$$A = (k_i, s_i) = \arg \max_{k,s} |c_{k,s} y_i^{Hf}| \quad (1)$$

در این رابطه، i شماره‌ی قطعه، k شماره‌ی خوشه، s شماره‌ی مقیاس، $C_{k,s}$ اتم سنترئوید^۶ متناظر با خوشه‌های k -means و y_i^{Hf} مولفه‌ی فرکانس بالای هر قطعه است. در گام دوم بردارهای ضرایب عددی با رابطه‌ی (۲) محاسبه می‌شوند.

$$(\hat{\alpha}_i, \hat{\beta}_i) = \arg \min_{\alpha_i, \beta_i} \left\{ \|y_i - D_i^A \alpha_i\|_2^2 + \lambda_1 \|\alpha_i\|_0 + \lambda_2 \|\alpha_i - \beta_i\|_0 \right\} \quad (2)$$

در این رابطه، λ_1 و λ_2 ضرایب لاگرانژ، α_i بردار اسپارس ضرایب قطعه‌ی حذف نویز شده‌ی i -ام و β_i بردار اسپارس ضرایب قطعه‌ی بدون نویز است. پس از محاسبه‌ی اسپارس تمام قطعات ($\hat{\alpha}_i$)، قطعات حذف نویز شده ($D_i^A \hat{\alpha}_i$) به دست می‌آیند. دیگرام کلی روش MSBTD در شکل (۳) قابل مشاهده است.




شکل (۳) - دیگرام روش MSBTD

روش MSBTD کارایی و عمل کرد قابل قبولی در بین روش‌های کاهش نویز دارد. با اعمال این روش روی تصاویر خام پایگاه داده، میانگین پیک نسبت سیگنال به نویز^۷ روی تصاویر اصلاح و حذف نویز شده برابر با ۲۰ دسی‌بل به دست آمده است. نمونه‌ای از یک تصویر خام و تصویر حذف نویز شده‌ی آن در شکل (۴) ارائه شده است.

همدوسی اپتیکی، اسپکل^۱ بوده و از روش MSBTD^۲ برای حذف آن استفاده می‌شود [۲۱]. این روش شامل دو مرحله‌ی آموزش دیکشنری^۳ و کاهش نویز است. تصاویر B-scan به صورت $Y \in \mathbb{R}^{N \times M \times L}$ تعریف شده که N و M ابعاد تصاویر و L تعداد تصاویر هر فرد است. تصاویر قطعه‌بندی شده و هر قطعه^۴ با اندازه‌ی $Q = N' \times M'$ به صورت $x = D\alpha$ و $x \in \mathbb{R}^Q$ تعریف می‌شود. مجموعه‌ی ترکیب خطی توابع پایه، دیکشنری (D) نامیده شده و α یک بردار ضرایب عددی است. در این روش از ۵ تصویر نزدیک به تصویر هدف در هر فرد، میانگین گرفته شده و از این تصاویر برای ایجاد دیکشنری استفاده می‌شود. راه حل پیشنهادی این روش برای کاهش نویز به صورت زیر است.

$$\hat{\alpha} = \arg \min_{\alpha} \|\alpha\|_0 \\ \|x^{noise} - D\alpha\|_2 \leq \omega$$

در این روابط x^{noise} قطعه‌ی نویزی و ω مقدار خطا است. در روش MSBTD آموزش دیکشنری توسط الگوریتم K-SVD روی قطعات انجام شده و برای پوشش بهتر روی ساختارهای مختلف از زیردیکشنری‌ها^۵ استفاده می‌شود. در روش MSBTD با استفاده از الگوریتم k -means، ۷۰ خوشه‌ی ساختاری ایجاد شده و سپس با استفاده از تحلیل مولفه‌ی اصلی، از هر خوشه یک زیردیکشنری به دست می‌آید. در این روش برای حاصل شدن اطلاعات ساختاری و بافتی مناسب، از دو مرحله Upsample و سه مرحله Downsample استفاده شده است. دیگرام آموزش دیکشنری در شکل (۲) قابل مشاهده است.



شکل (۲) - دیگرام آموزش دیکشنری

^۵ Subdictionary

^۶ Centroid Atom

^۷ Peak Signal To Noise Ratio (PSNR)


^۱ Speckle

^۲ Multiscale Sparsity Based Tomographic Denoising

^۳ Dictionary

^۴ Patch

اختلاف میان مرز به دست آمده در هر ستون تصویر و مینیمم مرز محاسبه شده و آن ستون به اندازه‌ی مقدار محاسبه شده جابه‌جا می‌شود. چند نمونه از اختلاف مرز پایین شبکه با مینیمم مرز (نقاط زرد) با فلش‌های سیاه در شکل (۵-الف) و تصویر مسطح شده در شکل (۵-ب) نشان داده شده است.



شکل (۵) - الف) تصویر حذف نویز شده، ب) تصویر مسطح شده

۲-۱-۳- برش تصویر


در گام آخر بخش پیش پردازش، میانگین ارتفاع لایه‌ی اپیتلیوم رنگ‌دانه‌ی شبکیه‌ی صاف شده محاسبه شده، به اندازه‌ی ۱۲۲ پیکسل بالاتر و پایین‌تر از آن نگه داشته شده و ۵۰ پیکسل از طرفین تصویر حذف می‌شود. این کار به دلیل وجود حاشیه در تصویر و نیز تمرکز بر قسمت اصلی تصویر یعنی شبکیه و لایه‌ی اپیتلیوم رنگ‌دانه، که بیماری دژنراسیون وابسته به سن ماکولا روی این لایه تاثیر می‌گذارد، انجام می‌شود. نمونه‌ی یک تصویر بعد از اعمال مرحله‌ی برش در شکل (۶) نشان داده شده است.



شکل (۶) - تصویر برش داده شده و اصلاح شده در پیش پردازش

۲-۲- استخراج ویژگی‌ها

در این بخش ویژگی‌ها به صورت بردار متشکل از اعداد حقیقی، از روی تصاویر اصلاح شده در بخش پیش‌پردازش، برای ارائه به بخش طبقه‌بندی استخراج می‌شوند. این بخش شامل چهار مرحله‌ی هرم فضایی، لبه‌یابی و آستانه‌گذاری، هیستوگرام گردادیان‌های جهت‌دار و تحلیل مولفه‌های اصلی می‌باشد.



شکل (۴) - الف) تصویر خام، ب) تصویر حذف نویز شده

۲-۱-۲- اصلاح انحنای شبکه

تصاویر شبکیه معمولاً دارای یک انحنای طبیعی بوده که ناشی از شیوه‌های دریافت و نمایش تصاویر است. برای کاهش اثرات انحنای شبکیه روی طبقه‌بندی کننده، باید انحنای شبکیه در هر تصویر مسطح شود. برای صاف کردن انحنای شبکیه در هر تصویر، ابتدا یک برآورد آزمایشی از لایه‌ی اپیتلیوم رنگ‌دانه‌ی شبکیه^۱ (دارای بیش‌ترین بازتاب نور در تصویر شبکیه) به دست آورده شده و سپس دو نقطه در هر ستون که دارای بیش‌ترین بازتابش نور هستند، انتخاب شده و میانگین مختصات آن‌ها به عنوان محل لایه‌ی اپیتلیوم رنگ‌دانه‌ی شبکیه تخمین زده شده است. در شکل (۴-الف)، نقاط آبی پررنگ نشان دهنده‌ی این لایه است. پس از آن بدنه‌ی محدب^۲ در اطراف نقاط به دست آمده محاسبه شده و مرز پایین بدنه‌ی محدب به عنوان برآورد مرز پایین شبکیه در نظر گرفته شده است. بدنه‌ی محدب طبق رابطه‌ی (۳) تعریف می‌شود [۲۲].

$$\text{conv}(X) := \left\{ \sum_{i=1}^n \lambda_i x^i \mid \lambda_1, \dots, \lambda_n \geq 0, \sum_{i=1}^n \lambda_i = 1 \right\} \quad (3)$$

در این رابطه، $X = \{x^1, \dots, x^n\}$ مجموعه‌ی نقاطی است که بدنه‌ی محدب آن‌ها محاسبه می‌شود و λ_i ضرایبی هستند که باید محاسبه شده و در معادله صدق کنند. در شکل (۵-الف)، مجموع دو منحنی سبز و قرمز نشان دهنده‌ی بدنه‌ی محدب و منحنی قرمز بیانگر مرز باین شبکه است. برای حذف انحناء،

[†] Convex Hull¹ Retinal Pigment Epithelium (RPE)

فیلتر کنی بسیار نزدیک به محل لبه‌های واقعی بوده و هم‌چنین این فیلتر برای هر نقطه‌ی لبه، تنها یک نقطه ارائه می‌دهد. مشتق‌های تصویر در جهت‌های افقی و عمودی با استفاده از روابط (۶)، (۷) و (۸) محاسبه می‌شود.

$$G(x, y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (۶)$$

$$\nabla G = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial G}{\partial x} \\ \frac{\partial G}{\partial y} \end{bmatrix} \quad (۷)$$


$$\nabla S = \begin{bmatrix} G_x \\ G_y \end{bmatrix} * Image \quad (۸)$$

جهت و اندازه‌ی S نیز با روابط (۹) و (۱۰) محاسبه می‌شود.

$$m = \sqrt{S_x^2 + S_y^2} \quad (۹)$$

$$\theta = \tan^{-1} \frac{S_y}{S_x} \quad (۱۰)$$

سپس لبه‌های گرادیانی شناسایی شده با استفاده از الگوریتم Non-Max-Suppression نازک‌سازی شده و یک نقطه در جهت لبه‌ی واقعی انتخاب می‌شود. برای شناسایی لبه‌های واقعی از دو آستانه‌ی بالا و پایین استفاده می‌شود. به طوری که مقادیر S بیش‌تر از آستانه‌ی بالا به عنوان لبه، مقادیر S کم‌تر از آستانه‌ی پایین به عنوان غیرلبه و مقادیر بین دو آستانه در صورت اتصال به لبه‌ی در نظر گرفته شده به عنوان لبه تشخیص داده می‌شوند. فیلتر لبه‌یابی کنی روی چهار تصویر تولید شده با هرم فضایی اعمال شده و تصاویر فیلتر شده جهت استخراج ویژگی‌ها به مرحله‌ی بعد منتقل می‌شوند. نتایج اعمال فیلتر کنی روی تصاویر مرحله‌ی قبل در شکل (۸) ارائه شده است.



۲-۲-۳- هیستوگرام گرادیان‌های جهت‌دار

یکی از روش‌های قدرت‌مند برای استخراج ویژگی از تصاویر روش هیستوگرام گرادیان‌های جهت‌دار است [۲۶]. بیماری


۲-۲-۱- هرم فضایی

برخی از آسیب‌های شبکیه مانند دژنراسیون وابسته به سن ماکولا، ویژگی‌هایی کلیدی را در مقیاس‌های مختلف نشان می‌دهند. بنابراین استفاده از هرم فضایی [۲۳، ۲۴] بسیار مفید است. در هر گام که هرم فضایی در جهت کاهشی مورد استفاده قرار می‌گیرد، ابعاد تصویر نصف می‌شود. برای محاسبه‌ی مقادیر جدید پیکسل‌ها از روابط (۴) و (۵) در جهت هر بعد استفاده می‌شود. به این ترتیب که مقادیر ۵ پیکسل با ضرایب $w(m)$ هم جمع شده و مقدار پیکسل تصویر جدید را ایجاد می‌کنند.

$$g_{new}(i) = \sum_{m=-2}^{+2} w(m) \times g_{old}(2i+m) \quad (۴)$$

$$w(m) = \left[\frac{1}{4} - \frac{a}{2}, \frac{1}{4}, a, \frac{1}{4}, \frac{1}{4} - \frac{a}{2} \right] \quad (۴)$$

در این روابط g_{new} مقدار پیکسل جدید و g_{old} مقدار پیکسل تصویر قبل از گام هرم فضایی بوده و پارامتر a برای ایجاد ضرایب $w(m)$ در برابر 0.37 در نظر گرفته شده است. نتیجه‌ی اعمال سه سطح هرم فضایی در شکل (۷) ارائه شده است. تصاویر مراحل پایین در شکل (۷)، جهت وضوح دیداری بزرگ‌نمایی شده و برابر با نصف اندازه‌ی مرحله‌ی قبل نیستند.



۲-۲-۲- لبه‌یابی و آستانه‌گذاری

با توجه به تاثیرگذاری بیماری دژنراسیون وابسته به سن ماکولا روی لایه‌ی اپیتلیوم رنگ‌دانه‌ی شبکیه و بازتاب بالای این لایه نسبت به سایر لایه‌ها در تصویربرداری، با یک فیلتر لبه‌یابی و یک سطح آستانه‌ی^۱ مناسب می‌توان این لایه را به صورت موثری استخراج کرد. فیلتر استفاده شده در این مطالعات، فیلتر کنی^۲ است [۲۵]. این فیلتر عمل‌کرد بسیار خوبی برای شناسایی موثر لبه‌ها ارائه می‌دهد. به این صورت که لبه‌های واقعی را به خوبی تشخیص داده و خطای بسیار کمی در تشخیص درست لبه‌ها دارد. محل لبه‌های شناسایی شده با

^۱ Canny

^۲ Threshold

در این روابط، X داده‌ها، C ماتریس کوواریانس و μ برداری است که هر درایه‌ی آن برابر با میانگین سطر متناظر با خود می‌باشد. ماتریس بردارهای ویژه با رابطه‌ی (۱۳) محاسبه می‌شود.

$$W^{-1}CW = D \quad (13)$$

در این رابطه، W ماتریس بردارهای ویژه و D ماتریس قطری است که درایه‌های قطر آن برابر با مقادیر ویژه می‌باشد. با توجه به مساله و میزان اهمیت و تاثیر ویژگی‌ها، تعدادی از مهم‌ترین ویژگی‌ها یا همان ستون‌های W ، انتخاب شده و سایر ویژگی‌ها نادیده گرفته شده‌اند. با ضرب داده‌های ورودی در ماتریس منتخب W ، ویژگی‌های مهم و مورد نظر باقی می‌مانند. تعداد ویژگی‌ها به عنوان متغیر مورد مطالعه قرار گرفته و بهترین نتیجه با استفاده از ۱۳ ویژگی به دست آمده است.

۲-۳- طبقه‌بندی

در مرحله‌ی سوم، ویژگی‌های استخراج و اصلاح شده باید به طبقه‌بند اعمال شوند. یکی از روش‌های طبقه‌بندی موثر طبقه‌بند گروهی AdaBoost است [۲۸]. در این روش از چند طبقه‌بند ضعیف^۲ از یک نوع استفاده می‌شود. در طبقه‌بند ضعیف اول، داده‌ها طبقه‌بندی شده، تعدادی از داده‌ها که طبقه‌بندی آن‌ها اشتباه است با الگوریتم AdaBoost انتخاب شده، به طبقه‌بند ضعیف سطح دو ارائه می‌شوند و این کار با توجه به تعداد سطح‌ها (تعداد طبقه‌بندهای ضعیف) ادامه پیدا می‌کند. انتخاب داده‌ها به صورت احتمالی بوده و احتمال انتخاب داده‌هایی که در سطح قبل غلط تشخیص داده شده‌اند، با الگوریتم AdaBoost افزایش می‌یابد. درخت تصمیم^۳ [۲۹] یکی از متداول طبقه‌بندهای ضعیف برای طبقه‌بند گروهی AdaBoost و مساله‌ی دوکلاسه است. تعداد طبقه‌بندهای ضعیف درخت تصمیم، به صورت متغیر مورد بررسی قرار گرفته و بهترین نتیجه با استفاده از ۱۵ درخت تصمیم به دست آمده است. در طبقه‌بندهای ضعیف، ویژگی‌ها با استفاده از شاخص Gini امتیازدهی شده و به ترتیب امتیاز در قسمت شروع، اولیه و مهم‌تر درخت قرار می‌گیرند. در واقع برای این که درخت تصمیم تشخیص دهد که کدام ویژگی‌ها می‌توانند اطلاعات بیش‌تری را ارائه دهند از شاخص Gini استفاده می‌شود. هر چه شاخص Gini کم‌تر باشد، ویژگی دارای اطلاعات بیش‌تری است. شاخص Gini به صورت رابطه‌ی (۱۴) تعریف می‌شود [۳۰].

$$Gini: \sum_{k=1}^K \hat{p}_{mk}(1 - \hat{p}_{mk}) = 1 - \sum_{k=1}^K \hat{p}_{mk}^2 \quad (14)$$

دژنراسیون وابسته به سن ماکولا باعث ایجاد اعوجاج در لایه‌ی اپیتلیوم رنگ‌دانه‌ی شبکیه و تپه مانند شدن آن می‌شود. روش هیستوگرام گرادیان‌های جهت‌دار به میزان زوایه و جهت تغییرات حساس بوده و بنابراین تفکیک‌پذیری مناسبی را برای نمونه‌های این بیماری ارائه می‌دهد. از این‌رو برای توصیف موثر شکل و ظاهر ساختارهای مورفولوژیکی در هر تصویر از توصیف‌گر هیستوگرام گرادیان‌های جهت‌دار استفاده شده است. این الگوریتم تصویر را به مناطق متصل به هم (سلول) تقسیم کرده، تعدادی از سلول‌ها را به عنوان یک بلوک در نظر گرفته و هر بلوک می‌تواند با بلوک بعدی هم‌پوشانی داشته باشد. در این پژوهش اندازه‌ی سلول‌ها برابر با 4×4 ، اندازه‌ی بلوک‌ها برابر با 2×2 و هم‌پوشانی بلوک‌ها برابر با ۵۰٪ مقداردهی شده است. گرادیان‌های عمودی و افقی هر پیکسل در هر سلول از بلوک‌ها به ترتیب با کم کردن مقادیر پیکسل بالا از پیکسل پایین و پیکسل چپ از راست و اندازه و جهت گرادیان با استفاده از روابط (۹) و (۱۰) محاسبه شده است. برای تولید هیستوگرام، جهت‌ها بین صفر تا ۱۸۰ درجه با گام ۲۰ درجه، به ۹ قسمت تقسیم شده و در هر سلول مقادیر اندازه‌ی گرادیان‌ها با توجه به این که در کدام قسمت از گام‌های ۲۰ درجه‌ای قرار دارند، با هم جمع شده است. سپس تمامی هیستوگرام‌های محاسبه شده در چهار سطح هرم فضایی تصویر، کنار هم الحاق^۱ شده و بردار ویژگی یک فرد را تشکیل می‌دهند. این کار برای تصاویر تمام افراد مورد مطالعه انجام شده و در نهایت تمامی بردارهای ویژگی زیر هم الحاق شده تا ماتریس ویژگی‌ها به دست آید.

۲-۲-۴- تحلیل مولفه‌ی اصلی

با توجه به بزرگ بودن ابعاد تصاویر مقطع‌نگاری همدوسی اپتیکی و نیز اعمال سه مرحله هرم فضایی، ابعاد بردارهای ویژگی بزرگ می‌باشد. از این‌رو برای کاهش مفید و موثر ابعاد بردارهای ویژگی و نیز افزایش تفکیک‌پذیری از روش تحلیل مولفه‌ی اصلی [۲۷] استفاده می‌شود. الگوریتم تحلیل مولفه‌ی اصلی، داده‌ها را به فضایی نگاشت کرده که بزرگ‌ترین واریانس داده روی اولین محور مختصات و دومین واریانس بزرگ روی دومین محور مختصات قرار می‌گیرد. محورهای مختصات در داده‌ها همان ویژگی‌ها هستند. ماتریس کوواریانس داده‌ها با استفاده از روابط (۱۱) و (۱۲) محاسبه می‌شود.

$$B = X - \mu \quad (11)$$

$$C = B \cdot B^* \quad (12)$$

^۳ Decision Tree

^۱ Concatenate

^۲ Weak Learner

۲-۳- ارزیابی

در این پژوهش روشی جدید و هوشمندانه برای شناسایی بیماری دژنراسیون وابسته به سن ماکولا ارائه شده است. پایگاه داده‌ی مورد استفاده شامل ۲۶۹ فرد بیمار و ۱۱۵ فرد سالم است. به طور معمول در سیستم‌های طبقه‌بندی ۷۰٪ داده‌های موجود در پایگاه داده جهت آموزش سیستم طبقه‌بندی و ۳۰٪ باقی‌مانده جهت آزمون سیستم، در نظر گرفته می‌شوند. به این ترتیب داده‌های ۱۸۸ فرد بیمار و ۸۰ فرد سالم برای آموزش سیستم طبقه‌بندی و داده‌های ۸۱ فرد بیمار و ۳۵ فرد سالم جهت آزمون سیستم در نظر گرفته شده است. روش طراحی شده در این پژوهش با استفاده از نرم‌افزار Matlab 2018b روی سیستم رایانه‌ای با مشخصات سخت‌افزاری CPU intel core i5- GPU Nvidia 1060, RAM DDR4 16GB 3000MHz, 7500 SSD 120Gb Sata پیاده‌سازی شده است. در تحقیقات مربوط به حوزه‌ی پزشکی، برای ارزیابی سیستم‌های شناسایی از سه مشخصه‌ی دقت، حساسیت و خاصیت بهره گرفته شده که به ترتیب با استفاده از روابط (۱۵)، (۱۶) و (۱۷) محاسبه می‌شوند.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (15)$$

$$\text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (16)$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (17)$$


در این روابط، TP آسیبی که به عنوان آسیب شناسایی شده، TN سالمی که به عنوان سالم شناسایی شده، FP سالمی که به عنوان آسیب شناسایی شده و FN آسیبی که به عنوان سالم شناسایی شده می‌باشد. دقت به صورت توانایی یک تست در افتراق صحیح موارد بیمار صحیح و سالم صحیح از سایر موارد، حساسیت به صورت توانایی یک تست برای پیدا کردن موارد بیماری صحیح و خاصیت به صورت توانایی یک تست برای پیدا کردن موارد سالم درست تعریف می‌شود. باید توجه داشت که در سیستم طراحی و پیاده‌سازی شده، تعداد ویژگی‌های اصلی در بخش تحلیل مولفه‌ی اصلی و تعداد طبقه‌بندی‌های ضعیف درخت تصمیم به صورت متغیر در نظر گرفته شده است. نمودار دقت بر اساس تعداد ویژگی‌های منتخب در شکل (۱۰) ارائه شده که در آن چهار منحنی وجود دارد. پارامتر T در شکل‌های (۱۰)، (۱۱) و (۱۲) بیان‌گر تعداد طبقه‌بندی‌های ضعیف مورد استفاده در الگوریتم AdaBoost است. هر منحنی بر اساس تعداد طبقه‌بندی‌های ضعیف (به ترتیب ۲، ۵، ۱۰ و ۱۵) رسم شده است. مشاهده می‌شود که بهینه‌ترین نقطه در نمودار (دقت

در این رابطه، K تعداد کلاس‌ها و p_{mk} احتمال ویژگی m با برچسب کلاس k است. الگوریتم دسته‌بندی مورد استفاده در درخت تصمیم، الگوریتم CART است [۳۱] که برای ساخت درخت تصمیم، داده‌ها را در هر شاخه به دو قسمت تقسیم کرده و بر اساس آن‌ها درخت دودویی (باینری) را می‌سازد.

۳- یافته‌ها و بحث

۳-۱- پایگاه داده

در این پژوهش از پایگاه داده‌ی تصاویر مقطع‌نگاری همدوسی اپتیکی بیماری دژنراسیون وابسته به سن ماکولا استفاده شده بوده که توسط دانشگاه دوک^۱، دانشگاه اموری^۲، بنیاد چشم دورس^۳ و بنیاد ملی چشم آمریکا^۴ تهیه شده [۱۶] و در تارنمای ClinicalTrials.gov با شماره‌ی ثبتی NTC00734487 به ثبت رسیده است. سیستم مورد استفاده جهت تصویربرداری ساخت شرکت Bioptigen است. سن افراد مورد مطالعه در این پایگاه داده بین ۵۰ تا ۸۵ سال بوده، هیچ‌کدام از آن‌ها جراحی شبکیه نداشته و دارای بیماری‌های چشمی که باعث تاثیر در نتیجه‌ی تصویربرداری می‌شوند، نبوده‌اند. این پایگاه داده دارای ۲۶۹ فرد بیمار و ۱۱۵ فرد سالم بوده که از هر نفر ۱۰۰ عکس B-Scan با ابعاد ۵۱۲×۱۰۰۰ موجود است. هر تصویر B-Scan شامل ۱۰۰۰ سیگنال A-Scan است. نمونه‌هایی از تصاویر موجود در این پایگاه داده در شکل (۹) ارائه شده است.



شکل (۹) - الف) نمونه‌ی تصاویر شبکیه‌های کنترل (سالم)، ب) نمونه‌ی تصاویر شبکیه‌های آسیب (بیمار)

^۱ Devers Eye Institute

^۲ National Eye Institute

^۳ Duke University

^۴ Emory University

با توجه به سه نمودار دقت، حساسیت و خاصیت نتیجه گرفته می‌شود که بهینه‌ترین نقطه، نقطه‌ای است که در هر سه نمودار روی منحنی با T برابر ۱۵ مشخص شده است. به این ترتیب با ۱۳ بعد یا ویژگی اصلی منتخب در الگوریتم تحلیل مولفه‌ی اصلی و ۱۵ طبقه‌بند ضعیف، بهترین نتیجه با مقدار ۱۰۰٪ برای هر سه شاخص دقت، حساسیت و خاصیت به دست آمده است. با حذف هر یک از بلوک‌های بخش پیش‌پردازش در صورت ثابت باقی ماندن سایر متغیرها، نتایج جدول (۲) به دست آمده است. این نتایج نشان می‌دهد که هر کدام از بلوک‌های پیش‌پردازش، ضروری بوده و در بهبود نتایج تاثیر زیادی دارند. نکته‌ی قابل توجه در حذف بلوک برش این است که داده‌های اضافی قابل توجهی به سیستم اضافه شده و بار محاسباتی بسیار زیادی را به وجود می‌آورد که باعث کند شدن بسیار زیاد سیستم می‌شود. میزان داده‌ها برای هر بردار ویژگی برای هر تصویر، بدون بلوک برش در حدود ۱۳۰۰۰۰۰ و با برش تصاویر در حدود ۶۰۰۰۰۰ اندازه‌گیری شده است. مشاهده می‌شود که بلوک برش باعث کاهش ۵۳ درصدی داده‌های ورودی به طبقه‌بند می‌شود.

جدول (۲) - نتایج حاصل از حذف بلوک‌های پیش‌پردازش


	بدون کاهش	بدون اصلاح انحنای شبکه	بدون برش
دقت	۹۳/۹	۹۱/۳	۸۴/۴
حساسیت	۱۰۰	۹۳/۸	۹۸/۷
خاصیت	۸۰	۸۵/۷	۵۱/۴

برای بررسی اثرات هر یک از بلوک‌های استخراج ویژگی، با ثابت نگه داشتن سایر متغیرها، بلوک‌ها به نوبت حذف شده و نتایج طبقه‌بند اندازه‌گیری می‌شود که این نتایج در جدول (۳) ارائه شده است. بلوک تحلیل مولفه‌ی اصلی باعث کاهش ویژگی‌ها و سریع‌تر شدن سیستم شده به طوری که تعداد ویژگی‌های استخراج شده از هر تصویر از حدود ۶۰۰۰۰۰ به ۱۳ ویژگی موثر که بهترین نتیجه‌ی سیستم با این تعداد ویژگی به دست می‌آید، کاهش پیدا کرده و در نتیجه زمان طبقه‌بندی سیستم از ۱۷۷ به ۱/۲ ثانیه کاهش پیدا کرده است. مشاهده می‌شود که بلوک تحلیل مولفه‌ی اصلی باعث افزایش تفکیک‌پذیری داده‌ها و بهبود دقت، حساسیت و خاصیت سیستم شده است.


جدول (۳) - نتایج حاصل از حذف بلوک‌های استخراج ویژگی

	بدون هرم فضایی	بدون لبه‌یابی	بدون تحلیل مولفه‌ی اصلی
دقت	۹۸/۲	۹۸	۹۶/۵
حساسیت	۱۰۰	۹۸/۷	۹۷/۵
خاصیت	۹۴/۲	۹۷/۱	۹۴/۲


۱۰۰٪) روی منحنی با T برابر ۱۵ قرار دارد. این نقطه مشخص می‌کند که بهترین دقت با در نظر گرفتن ۱۵ طبقه‌بند ضعیف در طبقه‌بند گروهی Adaboost و ۱۳ ویژگی مهم و اصلی در الگوریتم تحلیل مولفه‌ی اصلی به دست می‌آید. هر چه تعداد ویژگی‌ها یا ابعاد داده‌های ورودی طبقه‌بند کم‌تر باشد، بار محاسباتی و پیچیدگی کم‌تر بوده و سرعت سیستم بیش‌تر است. اگر تعداد طبقه‌بندهای ضعیف مورد استفاده در طبقه‌بند گروهی AdaBoost کم‌تر باشد، پیچیدگی و بار محاسباتی کم‌تر بوده و سیستم سریع‌تر عملیات آموزش و آزمون را اجرا می‌کند. دو شاخص حساسیت و خاصیت نیز بر کیفیت سیستم تاثیرگذار بوده که نمودار آن‌ها بر اساس T و تعداد ویژگی‌های منتخب به ترتیب در شکل‌های (۱۱) و (۱۲) نشان داده شده است.



شکل (۱۰) - نمودار دقت



شکل (۱۱) - نمودار حساسیت



شکل (۱۲) - نمودار خاصیت

جدول (۵) - نتایج حاصل از روش‌های مختلف

مرجع	دقت	حساسیت	خاصیت
[۱۴]	۹۱/۴	۹۲/۴	۹۰/۵
[۱۲]	۹۴/۴	۹۶/۸	۹۲/۱
[۱۹]	۹۳/۴۵	۹۳/۸۲	۹۶/۴
[۱۳]	۹۸	۹۸	۹۸/۸
آدابوست (روش پیشنهادی)	۱۰۰	۱۰۰	۱۰۰

۴- نتیجه‌گیری

در این پژوهش روشی جدید برای شناسایی دقیق، سریع و با اطمینان بالای بیماری دژنراسیون وابسته به سن ماکولا بر اساس تصاویر مقطع‌نگاری همدوسی اپتیکی ارائه شده است. سیستم طراحی شده با موفقیت پیاده‌سازی شده و نتایج بسیار خوبی به همراه داشته است. این سیستم با تعمیم به سایر بیماری‌های مرتبط با ماکولا که قابل شناسایی با تصاویر مقطع‌نگاری همدوسی اپتیکی هستند، قابل بهبود است.

۵- مراجع

- [1] Webb and G. C. Kagadis, "Introduction to Biomedical Imaging," Medical Physics, vol. 30, no. 8, pp. 2267-2267, 2003.
- [2] L. M. Sakata, J. DeLeon-Ortega, V. Sakata and C. A. Girkin, "Optical coherence tomography of the retina and optic nerve - a review," The Canadian Journal of Chemical Engineering, vol. 137, no. 3, pp. 90-99, 2009.
- [3] E. Margalit and S. Sadda, "Retinal and optic nerve diseases," Artif Organs, vol. 27, pp. 74-963, 2003.
- [4] A. Puliafito, M. R. Hee, C. P. Lin, E. Reichel and J. S. Schuman, "Imaging of Macular Diseases with Optical Coherence Tomography," Ophthalmology, vol. 102, no. 2, pp. 217-229, 1995.
- [5] M. Libbrecht and W. Noble, "Machine learning applications in genetics and genomics," Nature Reviews, vol. 16, no. 6, pp. 2-231, 2015.
- [6] J. L. Prince and J. Links, "Basic Imaging Principles," Medical Imaging Signals and Systems, pp. 513-518, 2015.
- [7] A. Carass, A. Lang, M. Hauser, P. A. Calabresi, H. S. Ying and J. L. Prince, "Multiple-object geometric deformable model for segmentation of macular OCT," Biomed. Opt. Express, vol. 5, no. 4, pp. 1062-1074, 2014.
- [8] Lang, A. Carass, M. Hauser, E. S. Sotirchos, P. A. Calabresi, H. S. Ying and J. L. Prince, "Retinal layer segmentation of macular OCT images using boundary classification," Biomed. Opt. Express, vol. 4, no. 7, pp. 1133-1152, 2013.

در بخش استخراج ویژگی، خروجی بلوک هرم فضایی به صورت چهار تصویر با ابعاد ۹۰۰×۲۴۵ ، ۴۵۰×۱۲۳ ، ۲۲۵×۶۵ و ۱۱۳×۳۱ است. هر چه ابعاد تصویر بزرگ‌تر باشد، جزئیات بیش‌تری را ارائه داده و به بیان دیگر حاوی اطلاعات در مقیاس کوچک است و هر چه ابعاد تصویر کوچک‌تر باشد، حاوی اطلاعات در مقیاس بزرگ است. به این ترتیب برای استخراج اطلاعات در چهار مقیاس، اندازه‌ی سلول‌ها در بلوک هیستوگرام گرادین‌های جهت‌دار برابر با ۴×۴ در نظر گرفته شده است. با توجه به ابعاد تصاویر در مقیاس‌های مختلف به ترتیب نسبت ابعاد تصاویر به ابعاد سلول برابر با $[۲۲۵ \ ۶۱]$ ، $[۱۱۳ \ ۳۰]$ ، $[۶۵ \ ۱۶]$ و $[۳۱ \ ۷]$ بوده که نشان دهنده‌ی قابلیت خوب ابعاد سلول در استخراج ویژگی‌ها در مقیاس‌های بزرگ و کوچک است.

برای این‌که هیستوگرام گرادین‌های جهت‌دار، حساسیت کم‌تری نسبت به تغییرات روشنایی^۱ و اثر سایه^۲ داشته باشد، کنتراست پاسخ‌های محلی باید نرمال‌سازی شوند. بدین منظور می‌توان با اندازه‌گیری هیستوگرام محلی انرژی در مناطق چندگانه‌ی بزرگ‌تر (بلوک) و با استفاده از نتایج، تمام سلول‌های بلوک را نرمال‌سازی کرد. اندازه‌ی بزرگ بلوک با توجه به تعداد پیکسل‌ها در یک بلوک بزرگ، توانایی مهار تغییرات روشنایی محلی را کاهش داده و اندازه‌ی بلوک کوچک‌تر به کاهش اثر تغییرات روشنایی کمک می‌کند، در نتیجه با توجه به ابعاد سلول و تصاویر خروجی بلوک هرم فضایی، اندازه‌ی بلوک برابر با ۲×۲ انتخاب شده است. برای اطمینان از صحت نرمال‌سازی کنتراست، هم‌پوشانی برابر با ۱×۱ (۵۰%) مقداردهی شده است. در بلوک طبقه‌بند، بهترین نتیجه با طبقه‌بند گروهی AdaBoost به دست آمده است. نتایج حاصل از پنج طبقه‌بند بیز ساده^۳، کی-نزدیک‌ترین همسایه^۴، بوت استرپ^۵، ماشین بردار پشتیبان و آدابوست^۶ در جدول (۴) ارائه شده است.

جدول (۴) - نتایج حاصل از طبقه‌بند‌های مختلف

بیز ساده	دقت	حساسیت	خاصیت
کی-نزدیک‌ترین همسایه	۹۷/۴	۱۰۰	۹۱/۴
بوت استرپ	۹۶/۵۵	۱۰۰	۸۸/۵۷
ماشین بردار پشتیبان	۹۳/۹۶	۹۷/۵	۸۵/۷
آدابوست (روش پیشنهادی)	۱۰۰	۱۰۰	۱۰۰

نتایج طبقه‌بندی بیماری با استفاده از چند روش مختلف در جدول (۵) ارائه شده که نشان می‌دهد روش پیشنهادی عمل کرد بهتری نسبت به روش‌های پیشین داشته است.

^۱ K-Nearest Neighbors

^۲ Bootstrap Aggregating (Bagging)

^۳ Adaptive Boosting (Adaboost)

^۴ Illumination

^۵ Shadowing

^۶ Naive Bayes

- [18] R. Rasti, H. Rabbani, A. Mehridehnavi and F. Hajizadeh, "Macular OCT Classification Using a Multi-Scale Convolutional Neural Network Ensemble," *IEEE Transactions on Medical Imaging*, vol. 37, no. 4, pp. 1024-1034, 2018.
- [19] S. Lee, D. M. Baughman and A. Y. Lee, "Deep learning is effective for the classification of OCT images of normal versus Age-related Macular Degeneration," *Ophthalmology Retina*, vol. 1, no. 4, pp. 322-327, 2017.
- [20] C. C. S. I. D. Z. S. W. a. R. S. S. Apostolopoulos, "Retinet: Automatic AMD identification in OCT volumetric data," *ArXiv preprint arXiv:1610.03628*, 2016.
- [21] S. L. Q. N. J. I. C. T. a. S. F. L. Fang, "Sparsity based denoising of spectral domain optical coherence tomography images," *Biomedical Optics Express*, vol. 3, no. 5, pp. 927-942, 2012.
- [22] J. O. C. D. T. J.E. Goodman, in *Handbook of Discrete and Computational Geometry*, Boca Raton, FL, CRC press, 2017, p. 383.
- [23] S. Lazebnik, C. Schmid and J. Ponce, "Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories," in *IEEE Computer Vision*, 2006.
- [24] J. Wu and J. M. Rehg, "Where am I: Place instance and category recognition using spatial PACT," in *IEEE Conference on Computer Vision and Pattern Recognition*, 2008.
- [25] J. F. Canny, "A Computational Approach to Edge Detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 8, no. 6, pp. 679-698, 1986.
- [26] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *International Conference on Computer Vision & Pattern Recognition (CVPR)*, San Diego, 2005.
- [27] H. Abdi and L. Williams, "Principal component analysis," *Wiley interdisciplinary reviews: computational statistics*, vol. 2, no. 4, pp. 433-459, 2010.
- [28] J. Chan and D. Paelinckx, "Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery," *Remote Sensing of Environment*, vol. 112, no. 6, pp. 2999-3011, 2008.
- [29] Y. Song and L. Ying, "Decision tree methods: applications for classification and prediction," *Shanghai archives of psychiatry*, vol. 27, no. 2, pp. 130-135, 2015.
- [30] R. J. F. T. Hastie, "Tree-Based Methods," in *The Elements of Statistical Learning*, New York, Springer, 2009, p. 309.
- [31] G. T. Denison, B. K. Mallick and A. F. M. Smith, "A Bayesian CART algorithm," *Biometrika*, vol. 85, no. 2, pp. 363-377, 1998.
- [9] H. R. S. K. R. Kafieh, "A Review of Algorithms for Segmentation of Optical Coherence Tomography from Retina," *J Med Signals Sens.*, vol. 3, no. 1, pp. 45-60, 2013.
- [10] P. P. Srinivasan, L. A. Kim, P. S. Mettu, S. W. Cousins, G. M. Comer, J. A. Izatt and e. al, "Fully automated detection of diabetic macular edema and dry age-related macular degeneration from optical coherence tomography images," *Biomedical optics express*, vol. 5, pp. 3568-3577, 2014.
- [11] F. G. Venhuizen, B. v. Ginneken, B. Bloemen, M. J. v. Grinsven, R. Philipsen, T. T. C. Hoyng and C. I. Sánchez, "Automated age-related macular degeneration classification in OCT using unsupervised feature learning," in *SPIE Medical Imaging : Computer-Aided Diagnosis*, 2015.
- [12] W. Sun, X. Liu and Z. Yang, "Automated detection of age-related macular degeneration in OCT images using multiple instance learning," in *Ninth International Conference on Digital Image Processing (ICDIP 2017)*, 2017.
- [13] Y. Wang, Y. Zhang, Z. Yao, R. Zhao and F. Zhou, "Machine learning based detection of age-related macular degeneration (AMD) and diabetic macular edema (DME) from optical coherence tomography (OCT) images," *Biomedical Optics Express*, vol. 7, no. 12, p. 4928, 2016.
- [14] Albarrak, F. Coenen and Y. Zheng, "Age-related Macular Degeneration Identification In Volumetric Optical Coherence Tomography Using Decomposition and Local Feature Extraction," in *The 17th Annual Conference in Medical Image Understanding and Analysis*, 2013.
- [15] M. C. Y. Y. Liu, H. Ishikawa, G. Wollstein, J. S. Schuman and J. M. Rehg, "Automated macular pathology diagnosis in retinal OCT images using multi-scale spatial pyramid and local binary patterns in texture and shape encoding," *Medical Image Analysis*, vol. 15, no. 5, pp. 748-759, 2011.
- [16] S. Farsiu, S. J. Chiu, R. V. Oconnell, F. A. Folgar, E. Yuan, J. A. Izatt and C. A. Toth, "Quantitative Classification of Eyes with and without Intermediate Age-related Macular Degeneration Using Optical Coherence Tomography," *Ophthalmology*, vol. 121, no. 1, pp. 162-172, 2014.
- [17] Ravenscroft, J. Deng, X. Xie, L. Terry, T. H. Margrain, R. V. North and A. Wood, "AMD Classification in Choroidal OCT Using Hierarchical Texton Mining," *Advanced Concepts for Intelligent Vision Systems Lecture Notes in Computer Science*, pp. 237-248, 2017.