

Proposing an Automated System for Differentiating between Healthy Individuals and Patients with Diabetic Retinopathy

Mina Ghayoor¹, MSc, Hossein Pourghassem², Associate Professor

¹ Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran

² Digital Processing and Machine Vision Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran

minaghayoor1994@gmail.com,

h_pourghassem@iaun.ac.ir

Abstract

Diabetes is one of the most common diseases in the world, adversely affects different body organs. One of the most common causes of eye problems is diabetes. Analyzing retinal damage is one of the best ways to diagnose diabetes so one of the best ways to diagnose diabetes is to look at the damage to the retina. Hence, first, a highly applicable and effective method, which is a combination of the Wiener filter and the discrete wavelet transform (DWT), is used for the removal of noise from images. Afterward, the k-means clustering algorithm is used to remove the bad image sections including very light and very dark areas of the image. Next, the image color and shape features are extracted. We transfer the images to the lab space, which fits the eye more, to extract the image color features. To extract the image shape features, first the images are converted into grey images and then the shape features are extracted. After extracting the features, the number of features is reduced using the Principal Component Analysis (PCA) algorithm. Besides, the best and most effective features are also selected. Finally, the support vector machine classifier with different kernel is used to classify the features and images into two categories, namely the healthy participants and patients. The accuracy resulting from this algorithm using the test images is over 90%.

Keywords: Diabetic retinopathy, shape and color properties of images, principal component analysis, support vector machine

Received: 31 October 2019

Revised: 30 April 2020

Accepted: 10 September 2020

Corresponding Author: Dr. Hossein Pourghassem

Citation: M. Ghayoor, H. Pourghassem, "Proposing an automated system for differentiating between healthy individuals and patients with diabetic retinopathy", Journal of Intelligent Procedures in Electrical Technology, vol. 11, no. 44, pp. 1-19, Winter 2021 (in Persian).

ارائه یک سیستم خودکار برای تشخیص افراد سالم و افراد دارای بیماری رتینوپاتی دیابتی

مینا غیور نجف‌آبادی^۱، دانش‌آموخته کارشناسی ارشد - حسین پورقاسم^{۱،۲}، دانشیار

۱- دانشکده مهندسی برق - واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات پردازش تصویر و بینایی ماشین - واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

minaghayoor1994@gmail.com

h_pourghasem@iaun.ac.ir

خلاصه: دیابت یکی از شایع‌ترین بیماری‌ها در جهان است که آثار مخربی بر روی قسمت‌های مختلف بدن برجای می‌گذارد. از ابتدایی‌ترین قسمت‌هایی که دچار عارضه می‌شود چشم است. تحلیل صدمات وارد شده بر روی شبکه چشم از بهترین راه‌های تشخیص دیابت است. به همین علت ابتدا یک روش پرکاربرد و موثر برای حذف نویز تصاویر با ترکیب فیلتر وینر و تبدیل موجک گسسته اعمال می‌شود. در مرحله بعد از الگوریتم خوشه‌بندی k-means برای حذف قسمت‌های نامطلوب تصویر شامل نواحی خیلی روشن و خیلی تیره تصویر، استفاده می‌شود. سپس ویژگی‌های رنگ و شکل تصاویر استخراج می‌شود. برای استخراج ویژگی‌های رنگ تصویر، تصاویر را به فضای lab که برای چشم انسان بهتر قابل درک است برده می‌شود و برای استخراج ویژگی‌های شکل ابتدا تصاویر را به تصاویر خاکستری تبدیل کرده و سپس اقدام به استخراج ویژگی‌های شکل می‌گردد. پس از استخراج ویژگی‌ها به کمک الگوریتم تجزیه و تحلیل مؤلفه‌های اصلی تعداد ویژگی‌ها را کاهش داده و بهترین و مؤثرترین ویژگی‌ها انتخاب می‌شود. در پایان برای طبقه‌بندی ویژگی‌ها و تصاویر به دو گروه سالم و بیمار، از طبقه‌بند ماشین بردار پشتیبان با کرنل‌های متفاوت استفاده می‌شود. این الگوریتم صحت بالای ۹۰٪ برای تصاویر آزمایشی حاصل می‌کند.

کلمات کلیدی: رتینوپاتی دیابتی، ویژگی‌های شکل و رنگ تصاویر، تجزیه و تحلیل مؤلفه‌های اصلی، ماشین بردار پشتیبان

تاریخ ارسال مقاله: ۱۳۹۸/۸/۹

تاریخ بازنگری مقاله: ۱۳۳۹۹/۲/۱۱

تاریخ پذیرش مقاله: ۱۳۹۹/۶/۲۰

نام نویسنده مسئول: دکتر حسین پورقاسم

آدرس نویسنده مسئول: نجف‌آباد-دانشگاه آزاد اسلامی واحد نجف‌آباد-دانشکده مهندسی برق- گروه مهندسی پزشکی

۱- مقدمه

دیابت نوعی بیماری شایع در جهان است که آثار بدی روی چشم‌ها، سیستم عصبی، قلب و سایر اعضای بدن می‌گذارد. از اولین اعضای بدن که معمولاً دچار آسیب می‌شوند، چشم است و از سریع‌ترین راه‌های تشخیص بیماری دیابت، تحلیل عروق و عارضه‌های ناشی از صدمات وارد شده به عروق شبکیه چشم است. رتینوپاتی دیابتی از عوارض شایع بیماری دیابت روی شبکیه چشم انسان است که در صورت تشخیص دیر هنگام باعث کاهش دید و یا حتی نابینایی فرد مبتلا می‌شود [۱].

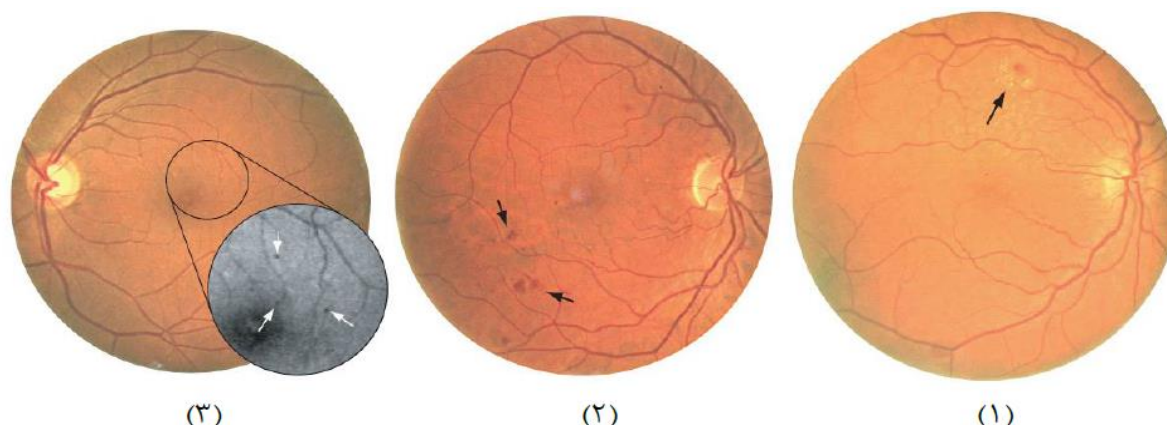
علت بیماری رتینوپاتی دیابتی افزایش میزان گلوکز در خون است که باعث ایجاد تغییراتی در دیواره عروق می‌شود. وقتی عروق خونی در شبکیه آسیب می‌بینند، ممکن است باعث نشت خون شده و یا منجر به رشد شاخه‌های عروقی شکننده و کلاف مانند شده و باعث تخریب شبکیه شود. رتینوپاتی دیابتی جزء شایع‌ترین و خطرناک‌ترین بیماری‌های سیستم بینایی انسان است و اصلی‌ترین عامل نابینایی در بزرگسالان بین ۲۰ تا ۶۰ سال است [۲].

بهترین راه برای تشخیص رتینوپاتی دیابتی معاینه چشم در فواصل منظم است که اصولاً هر ۱۲ ماه یکبار، توسط پزشک انجام می‌شود. در سال‌های اخیر به علت تعداد فراوان بیماران و حجم انبوه تصاویر، نیاز به نیروهای متخصص و هزینه‌های غربالگری افزایش یافته است و به دنبال آن کیفیت تشخیص بیماری و رضایتمندی بیماران کاهش یافته است. یک سیستم تشخیص رتینوپاتی دیابتی می‌تواند در رفع مشکلات ذکر شده تأثیر بسزایی داشته باشد. در این سیستم‌ها از تکنیک‌های پردازش تصویر برای تشخیص علائم بیماری استفاده می‌شود [۲].

تصاویر فوندوس شبکیه که نشان‌دهنده عمیق‌ترین سطح کره چشم است علاوه بر ساختارهای عادی شبکیه، شامل اطلاعاتی در مورد عوارض ناشی از رتینوپاتی دیابتی است. میکروآنوریزم^۱ اولین نشانه رتینوپاتی دیابتی است که ناشی از نشت خون به درون شبکیه است و به صورت لکه‌های دایروی کوچک قرمز رنگ با قطر کمتر از ۱۲۵ میکرومتر نمایان می‌شود. ضایعه آگزودا^۲ نشان‌دهنده تجمع چربی و پروتئین در شبکیه چشم است و معمولاً به صورت لکه‌های روشن در شبکیه مشاهده می‌شود. ضایعه خونریزی^۳ ناشی از نشت خون از عروق خونی در شبکیه است که به صورت لکه‌های قرمز رنگ ظاهر می‌شود. خونریزی هم‌رنگ با ضایعه میکروآنوریزم بوده و از نظر اندازه کمی بزرگتر از میکروآنوریزم است. این ضایعات در شکل (۱) قابل مشاهده است [۳].

برخی از روش‌هایی که تاکنون در زمینه تشخیص بیماری رتینوپاتی دیابتی براساس تصاویر شبکیه انجام شده است را در ادامه مورد بررسی قرار می‌دهیم. تاکنون تلاش‌های بسیاری در این زمینه انجام گرفته و روش‌های بسیاری پیشنهاد شده است. فرآیند تشخیص رتینوپاتی دیابتی شامل مراحل مختلفی است که هر کدام از مراحل ذکر شده دارای اهمیت و تأثیر زیادی است. بنابراین انتخاب و روند استفاده از ابزارها و الگوریتم‌های مختلف در هر مرحله بر عملکرد سیستم بسیار مؤثر است.

محققین در مرجع [۴] به‌طور خودکار نواحی ترشح التهابی و غیرترشح را در تصاویر شبکیه طبقه‌بندی می‌کنند. تکنیک ارائه شده بر پایه‌ی پیش پردازش برای استخراج زخم کاندید شده، ویژگی‌های زخم و طبقه‌بندی است. در پیش پردازش، فیلتر گابور^۴ به تصویر اعمال شده که برای بهبود زخم مفید است. تقسیم‌بندی زخم کاندید شده بر پایه مورفولوژی ریاضی است. یک مجموعه ویژگی برای هر زخم کاندید شده با استفاده از ترکیب ویژگی‌های هندسی و آماری انتخاب شده است. در این روش دقت ۹۸ درصد مشاهده شده است. در مرجع [۵] پیشنهاد شده که از روش‌های پیش‌پردازش جدید استفاده شود که تنها وظایف نوین برداری و نرمالیزاسیون را در بر نمی‌گیرد بلکه انعکاس‌ها و حالت‌های مصنوعی را نیز در تصویر شناسایی می‌کند. ساختارهای تیره تصویر با مورفولوژی ریاضی و ساختارهای روشن با یک الگوی وفقی^۵ طراحی شده حذف می‌گردند. این کاندیداها با استفاده از ویژگی‌های کلاسیک مشخص شده‌اند اما ویژگی‌های مفهومی جدید را نیز در برمی‌گیرند. این روش صحت بین ۹۳ درصد تا ۹۵ درصد در پایگاه‌های داده‌ی متفاوت نشان داده است. در مرجع [۶] یک تکنیک بر پایه پردازش مورفولوژی تصویر و منطق‌فازی برای تشخیص آگزودا در تصاویر شبکیه پیشنهاد شده است. دیسک نوری با استفاده از مورفولوژی ریاضی و آگزودا با استفاده از منطق‌فازی تشخیص داده می‌شود. این روش حساسیتی برابر ۷۵ درصد و دقت ۹۹ درصد به‌دست آورده است.



شکل (۱): ضایعات ناشی از رتینوپاتی دیابتی: (۱) اگزودا، (۲) خونریزی، (۳) میکروآنوریسم [۳]
Figure (1): Diabetic retinopathy lesions: (1) exudate, (2) hemorrhage, (3) microaneurysm [3]

در مرجع [۷] یک روش برای تشخیص خودکار میکروآنوریسم در تصاویر رنگی شبکیه مطرح شده است. تشخیص میکروآنوریسم توسط تجزیه و تحلیل پروفایل متقاطع بر روی پیکسل‌های حداکثر محلی انجام شده و مشاهده می‌شود پروفایل متقاطع برای مناطق دارای میکروآنوریسم یک پیک گوسی در تمامی جهتها از خود نشان می‌دهند. با استخراج یک مجموعه ویژگی از این پیک‌های گوسی ضایعه میکروآنوریسم شناسایی می‌شود. این روش امتیاز 0.42 را به دست آورده که به نسبت موارد مشابه امتیاز بالاتری است. در مرجع [۸] یک روش جدید برای تشخیص خونریزی شبکیه در تصاویر فوندوس ارائه شده است که در این روش تصاویر رنگی شبکیه به بخش‌های غیر همپوشان بخش‌بندی شده که کل تصویر را پوشش می‌دهد. هر بخش شامل پیکسل‌هایی با رنگ مشابه و موقعیت فضایی خاص است. برای قطعه‌بندی از الگوریتم‌های تپگان^۶ و واترشد^۷ استفاده شده است. به دلیل تغییرات در ظاهر خونریزی‌ها، ابتدا اندازه‌گرادیان تجمعی کنتراست محاسبه می‌گردد. تعداد قطعات در هر تصویر در یک محدوده مشخص مطرح شده و با میزان آستانه کار می‌کند. این روش در بهترین حالت ممکن صحت 96% را نشان داده است. در مرجع [۹] از الگوریتم تحلیل المان مورفولوژیکی^۸ استفاده شده تا بین ساختارهای معمول شبکیه و ساختارهای پاتولوژیکی تمایز قائل شود. تصاویر نرمال و غیرنرمال شبکیه با استفاده از ویژگی‌های آماری در ضایعات شبکیه تشخیص داده می‌شود. سیستم پیشنهادی دقت 92% و حساسیت $95/45\%$ درصد را در پایگاه داده انتخابی نشان داده است. در مرجع [۱۰] یک روش جدید برای تشخیص خودکار میکروآنوریسم و خونریزی در تصاویر فوندوس توصیف شده است. بدین منظور که یک مجموعه ویژگی جدید به نام ویژگی‌های دینامیکی شکل که به تقسیم‌بندی دقیق مناطق نیاز ندارد، معرفی شده است. در یک نمایش توپوگرافی هر کاندید مطابق با یک منبع آب در نظر گرفته شده است و با استفاده از این تعریف ویژگی‌ها استخراج شده است. در مرجع [۱۱] یک سیستم تشخیص میکروآنوریسم‌ها و خونریزی ارائه شده و برای تشخیص ضایعات یک نقشه‌ی احتمالی برای کاندیدها محاسبه می‌شود که تابع چگالی احتمال شرطی را برای هر ضایعه‌ی کاندید نشان می‌دهد. حساسیت ارائه شده توسط این سیستم 93% درصد گزارش شده است و در مقابل حساسیت ارائه شده توسط چندین متخصص 94% درصد است. در مرجع [۱۲] از دو تکنیک شناخته‌شده استخراج ویژگی تبدیل ویژگی مستقل از مقیاس^۹ (SIFT) و ویژگی‌های مقاوم تسریع‌شده^{۱۰} (SURF) به‌طور همزمان در هر تصویر شبکیه برای یافتن مناطق اگزودا استفاده می‌شود. این دو تکنیک اگزوداهای هر تصویر را در یک ماتریس ویژگی ذخیره می‌کند که به‌عنوان ورودی طبقه‌بند ماشین بردار پشتیبان برای تشخیص اگزودا اعمال می‌گردد. در این روش برای 100 تصویر مجموعه تست حساسیت 94% درصد به دست آمده است.

در تمامی الگوریتم‌های پیشنهادی تنها یک یا دو مورد از نشانه‌های بیماری رتینوپاتی دیابتی را تشخیص می‌دهند و تنها محدوده‌ی خاصی از تصویر که در رابطه با علامت انتخابی در آن روش است را مورد بررسی قرار می‌دهند در صورتیکه عدم وجود یکی از علائم بیماری به معنای سالم بودن شخص و عدم وجود بیماری نیست. برای اطمینان از سالم بودن شخص بررسی تمامی علائم بیماری الزامی است. به همین علت در الگوریتم پیشنهادی در این مقاله سعی شده روشی پیشنهاد گردد

که با استفاده از کل تصویر تمامی علائم بیماری بررسی گردد و بعد از بررسی هر سه علامت آگزودا، میکروآنوریزم و خونریزی تشخیص دهد فرد از نظر بیماری رتینوپاتی دیابتی سالم یا بیمار است.

در ادامه الگوریتم پیشنهادی که شامل سه مرحله کلی است بررسی می‌شود در مرحله اول پیش پردازش تصویر انجام می‌شود. در مرحله پیش پردازش ابتدا یک روش مناسب برای حذف نویز تصاویر معرفی و عملکرد آن بررسی می‌گردد و در ادامه نواحی نامطلوب تصاویر حذف می‌شود. در مرحله بعدی ویژگی‌های شکل و رنگ تصاویر استخراج می‌شود. در نهایت با استفاده از طبقه‌بندماشین بردار پشتیبان تصاویر سالم و بیمار از نظر بیماری رتینوپاتی دیابتی طبقه‌بندی می‌شود.

۲- روش پیشنهادی

الگوریتم پیشنهادی دارای سه مرحله اصلی پیش پردازش، استخراج ویژگی و طبقه‌بندی است که هر کدام از این مراحل از چند قسمت تشکیل شده است. مراحل الگوریتم پیشنهادی در شکل (۲) نشان داده شده است.

۲-۱- بانک داده

در این پژوهش از پایگاه داده High-Resolution Fundus (HRF) استفاده شده است که توسط یک گروه پژوهشی متشکل از آزمایشگاه شناسایی الگو (CS5)، گروه چشم پزشکی، دانشگاه فردریش الکساندر ارلانگن-نورنبرگ آلمان و دانشگاه تکنولوژی برنو، دانشکده برق و مخابرات، گروه مهندسی پزشکی، برنو (جمهوری چک) در جهت حمایت از الگوریتم‌های تقسیم‌بندی خودکار بر روی تصاویر فوندوس شبکیه ایجاد شده است. این مجموعه تصویر با استفاده از دوربین عکاسی Canon CR-1 با میدان دید ۴۵ درجه به دست آمده است. نمونه‌ای از تصاویر پایگاه داده HRF در تصویر (۳) مشاهده می‌کنید [۱۳].

۲-۲- پیش پردازش

در مرحله‌ی پیش پردازش ابتدا نویزهای تصویر توسط ادغام تبدیل موجک گسسته و فیلتر وینر و سپس نواحی نامطلوب تصویر توسط الگوریتم خوشه‌بندی K-means حذف می‌شود.

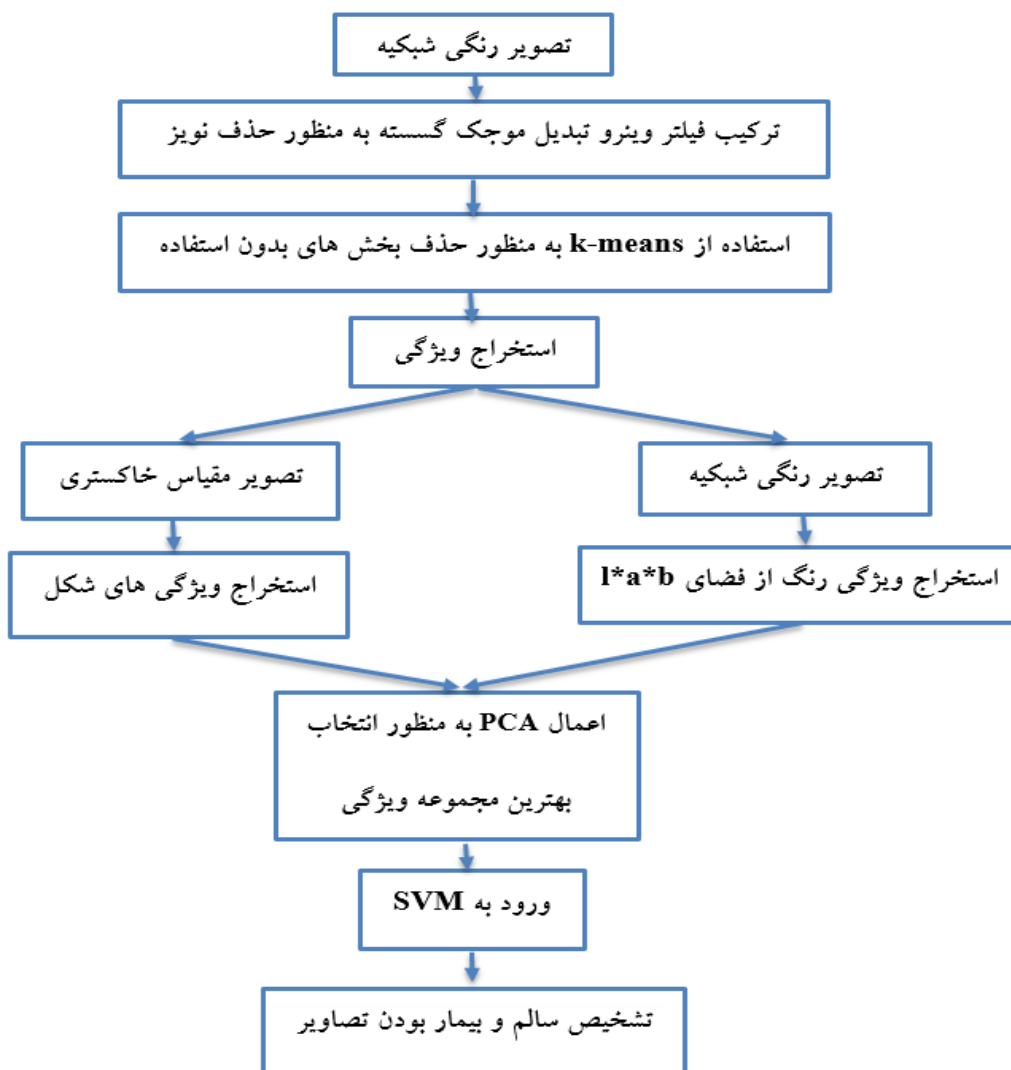
۲-۲-۱- حذف نویز تصاویر

موجک یکی از تبدیل‌های حوزه فرکانس است. هنگام پیاده‌سازی تبدیل موجک، تابع موجک شکل خود را حفظ می‌کند، اما در طول سیگنال جابه‌جا شده، فشرده و باز می‌شود و بدین ترتیب کل سیگنال را طی می‌کند. این روش برخلاف تبدیل فوریه قادر است تا تفکیک‌های متفاوتی برای محدوده‌های فرکانس پایین و بالا ایجاد کند [۱۳]. تبدیل موجک تصویر را به چهار زیرباند LL، HL، LH و HH تجزیه می‌کند که به ترتیب زیرباند فرکانس پایین، زیرباند میان فرکانسی و زیرباند فرکانس بالا هستند [۱۴].

شایان ذکر است که در فرآیند بازسازی سیگنال می‌توان برحسب نیاز تنها قسمت‌های معینی از آن را بازسازی کرد و به دلخواه بخش‌هایی از سیگنال را حذف کرد که از این قابلیت در نویززدایی استفاده می‌شود. در الگوریتم پیشنهادی بعد از آزمایش کردن چندین موجک، موجک دابوچی نوع سوم بهترین نتیجه را در جهت حذف نویز تصاویر و ترکیب با فیلتر وینر از خود نشان داد. یکی از مهمترین تکنیک‌ها برای حذف تاری تصاویر، فیلتر وینر است. فیلتر وینر میانگین مربع خطا بین فرآیند تصادفی تخمین زده شده و فرآیند مورد نظر را به حداقل می‌رساند.


کیفیت تصاویر موجود در پایگاه داده HRF بسیار مطلوب است و تصاویر بدون نویز و بسیار واضح است به همین دلیل برای بررسی روش حذف نویز ارائه شده برای بررسی سایر پایگاه‌های داده که دارای نویز هستند ابتدا به تصویر نویز اضافه کرده و سپس با روش ارائه شده نویزهای تصویر را حذف نموده ایم. در این روش حذف نویز ابتدا تصویر را تا دو سطح توسط تبدیل موجک گسسته تجزیه می‌کنیم، سپس به هر کدام از زیرسطح‌های تجزیه شده فیلتر وینر و قدرمطلق گیر اعمال می‌کنیم و در

نهایت تبدیل موجک گسسته معکوس تا دو سطح انجام داده و تصویر ابتدایی را بازسازی می‌کنیم. همانطور که در تصاویر مشاهده می‌کنید ترکیب فیلتر وینر و تبدیل موجک گسسته به خوبی می‌توانند نویزهای تصویر را حذف کنند.



شکل (۲): الگوریتم پیشنهادی شناسایی افراد سالم و بیمار از نظر بیماری رتینوپاتی دیابتی

Figure (2): Proposed algorithm to identify healthy and patients for diabetic retinopathy



شکل (۳): نمونه ای از تصاویر پایگاه داده HRF (الف) فرد بیمار (ب) فرد سالم

Figure (3): Example of HRF database images (a) Sick person (b) Healthy person

مشخصات فیلتر وینر استفاده شده نیز بدین شرح است ابعاد پنجره کوچک را از 1×1 تا 7×7 و ابعاد پنجره بزرگ را از 2×2 تا 15×15 تغییر دادیم و با مشاهده کیفیت ظاهری تصاویر و معیارهای عملکردی ابعاد پنجره کوچک 2×2 و ابعاد پنجره بزرگ 3×3 در نظر گرفته شد که بهترین نتیجه برای حذف نویز تصویر هم از نظر ظاهری و هم از نظر معیارهای عملکردی MSE و PSNR بدست آورد. هرچه پنجره‌های انتخابی دارای ابعاد کوچکتری باشد عمل حذف نویز بهتر انجام می‌شود البته ابعاد پنجره کوچک در صورتیکه 1×1 انتخاب شود تصویر حاصل سیاه می‌شود و ابعاد پنجره‌ی بزرگ تاثیری در این حالت ندارد. ابعاد پنجره از سایر مشخصات روش ارائه شده تاثیر بیشتری بر روی نتایج دارد. فاکتور را بین صفر تا ۱۰۰ تغییر داده و فاکتور ۹۰ بهترین حذف نویز را از نظر ظاهری و معیارهای ارزیابی ارائه کرد. فاکتورهای بسیار کوچک کمتر از یک بر روی نتایج تاثیر بیشتری دارد و در صورت افزایش مقدار فاکتور از ۰ تا ۱ نتایج تغییرات بیشتری دارد و افزایش مقادیر فاکتور از ۱ تا ۹۰ تاثیر کمتری بر نتایج دارد ولی به‌طوراندک نتایج بهتر می‌شود، افزایش مقدار فاکتور از ۹۰ تا ۱۰۰ تاثیر قابل توجهی در نتایج ندارد. در ادامه ابتدا نویزهای مختلف به تصویر اضافه شده و سپس با روش حذف نویز ارائه شده نویزهای اضافه شده به تصویر حذف می‌گردند و سپس معیارهای ارزیابی MSE و PSNR برای هر کدام محاسبه می‌شود.

الف- نویز فلفل نمکی


نویز فلفل نمکی یک نویز ضربه‌ای است که به‌صورت رابطه‌ی (۱) تعریف می‌گردد.

$$P(z) = \begin{cases} P_a & , \text{ for } z=a \\ P_b & , \text{ for } z=b \\ (1-P_a-P_b) & , \text{ otherwise} \end{cases} \quad (1)$$

اگر $b > a$ شدت b در تصویر به‌صورت نقاط روشن و a به‌صورت نقاط تاریک دیده می‌شود. P_a احتمال وقوع a و P_b احتمال وقوع b مقادیر نویز ضربه‌ای شبیه دانه‌های ریزنمک و فلفل هستند که به‌صورت تصادفی توزیع شده‌اند [۲۱]. نتایج اضافه‌شدن نویز فلفل نمکی به تصویر و سپس حذف آن توسط روش ارائه شده را روی تصاویر افراد دارای بیماری رتینوپاتی دیابتی و افراد سالم در شکل (۳) و (۴) مشاهده می‌کنید.

ب- نویز گوسی

نویز گوسی معمولاً مقادیر خاکستری را در تصاویر دیجیتال مختل می‌کند و مانند نویز سفید است با این تفاوت که دامنه‌ی فرکانسی کمتر است و برخلاف نویز سفید قابل رؤیت است. نویز گوسی باعث می‌شود تصاویر تار و کم‌رنگ به نظر برسند. نویز گوسی معمولاً با تابع چگالی احتمال برحسب مقادیر خاکستری با رابطه (۲) مدل می‌شود.



(ب)

(الف)

شکل (۳): اضافه و حذف نویز فلفل نمکی برای فرد سالم (الف) تصویر شبکیه یک فرد سالم که نویز فلفل نمکی با واریانس ۰/۰۳ به آن اضافه شده است (ب) تصویر شبکیه فرد سالم که حذف نویز شده

Figure (3): Addition and Removal of Salt Pepper Noise for Healthy Individual (a) Retina Image of a Healthy Person with Salt Pepper Noise with 0.03 Variance (b) Retina image of a healthy person with noise removal




شکل (۴): اضافه و حذف نویز فلفل نمکی برای فرد بیمار (الف) تصویر شبکیه یک فرد بیمار که نویز فلفل نمکی با واریانس ۰/۰۳ به آن اضافه شده است (ب) تصویر شبکیه فرد بیمار که حذف نویز شده

Figure (4): Addition and Removal of Salt Pepper Noise for a Sick Person (a) Retina image of a patient with salt pepper noise added with a variance of 0.03 (b) Retina image of the patient with noise removal

$$P(Z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\mu)^2}{2\sigma^2}} \quad (2)$$

که μ میانگین، σ انحراف معیار استاندارد است. نتایج اضافه شدن نویز گوسی به تصویر و سپس حذف آن توسط روش ارائه بر روی تصاویر افراد سالم و افراد دارای بیماری رتینوپاتی دیابتی شده را در شکل (۵) و (۶) مشاهده می‌کنید.



شکل (۵): اضافه و حذف نویز گوسی برای فرد سالم (الف) تصویر شبکیه یک فرد سالم که نویز گوسی با واریانس ۰/۰۱ به آن اضافه شده است (ب) تصویر فرد سالم که حذف نویز شده

Figure (5): Addition and Removal of Gaussian Noise for Healthy Individual (a) Retina image of a healthy person with Gaussian noise with variance of 0.01 (b) Image of healthy person with noise removal



شکل (۶): اضافه و حذف نویز گوسی برای فرد بیمار (الف) تصویر شبکیه یک فرد بیمار که نویز گوسی با واریانس ۰/۰۱ به آن اضافه شده است (ب) تصویر فرد بیمار که حذف نویز شد

Figure (6): Addition and Removal of Gaussian Noise for a Sick Person (a) Retina image of a patient with Gaussian noise added with 0.01 variance (b) Image of a sick with noise removal

ج- نویز اسپیکل

نویز اسپیکل یک آشفتگی نقطه ای است که به‌عنوان نویز ضرب شونده محسوب می‌شود. هنگامی که تعداد پراکنده سازها در یک ناحیه‌ی با تفکیک زیاد و فاز برگشتی به صورت یکنواخت بین ۰ تا ۲ توزیع شده باشد. فازور یا دامنه‌ی میدان مختلط حاصل از

این برآیند تصادفی دارای مولفه‌های حقیقی و موهومی و با تابع چگالی احتمال توأم گوسی با واریانس σ به صورت رابطه‌ی (۳) است.

$$P(E_r^2, E_i^2) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{E_r^2 + E_i^2}{2\sigma^2}\right) \quad (3)$$

نتایج اضافه شدن نویز اسپیکل به تصویر و سپس حذف آن توسط روش ارائه شده بر روی تصاویر افراد سالم و افراد دارای بیماری رتینوپاتی دیابتی را در شکل (۷) و (۸) مشاهده می‌کنید.



شکل (۷): اضافه و حذف نویز اسپیکل برای فرد سالم (الف) تصویر شبکیه یک فرد سالم که نویز گوسی با واریانس 0.01 به آن اضافه شده است (ب) تصویر فرد سالم که حذف نویز شده

Figure (7): Addition and Removal of Speckle Noise for Healthy person (a) Retina image of a healthy person with Speckle noise with variance of 0.01 (b) Image of healthy person with noise removal



شکل (۸): اضافه و حذف نویز اسپیکل برای فرد بیمار (الف) تصویر شبکیه یک فرد بیمار که نویز اسپیکل با واریانس 0.01 به آن اضافه شده است (ب) تصویر فرد بیمار که حذف نویز شده

Figure (8): Addition and Removal of Speckle Noise for a Sick Person (a) Retina image of a patient with Speckle noise added with a variance of 0.01 (b) Retina image of the patient with noise removal

د- ارزیابی عملکرد روش حذف نویز معرفی شده

برای درک بهتر عملکرد حذف نویز تصاویر توسط الگوریتم ترکیبی فیلتر وینر و تبدیل موجک گسسته می‌توان از معیار میانگین مربع خطا MSE و معیار نسبت نویز به سیگنال PSNR استفاده نمود. معیار MSE از رابطه (۴) محاسبه می‌گردد.

$$MSE = \frac{1}{RC} \sum_{r=1}^R \sum_{c=1}^C (s(r,c) - y(r,c))^2 \quad (4)$$

$S(r, c)$ تصویر اصلی بدون نویز، $y(r, c)$ تصویر حذف نویز شده، R و C نیز ابعاد تصویر هستند. معیار PSNR از رابطه (۵) محاسبه می‌گردد:

$$PSNR = 10 \log_{10} \left(\frac{\max_i^2}{MSE} \right) \quad (5)$$

\max_i بیشترین مقدار روشنایی تصویر است [۱۶]. نتایج محاسبه معیار میانگین مربع خطا و معیار نسبت نویز به سیگنال برای یک تصویر فرد سالم و فرد دارای بیماری رتینوپاتی دیابتی را می‌توان در جدول (۱) مشاهده نمود.

Table (1): Results of calculation of MSE and PSNR criteria

جدول (۱): نتایج محاسبه معیارهای MSE و PSNR

| معیار PSNR | معیار MSE | سالم/ بیمار | واریانس نویز | نویز اضافه شده به تصویر |
|------------|-----------|-------------|--------------|-------------------------|
| ۳۴/۶ | ۲۲/۵ | سالم | ۰/۰۱ | اسپکل |
| ۳۳ | ۳۲/۷ | بیمار | ۰/۰۱ | اسپکل |
| ۳۰/۵ | ۵۷/۷ | سالم | ۰/۰۱ | گوسی |
| ۳۰ | ۶۴/۵ | بیمار | ۰/۰۱ | گوسی |
| ۳۴/۳ | ۲۴/۳ | سالم | ۰/۰۱ | فلفل نمکی |
| ۳۲/۹ | ۳۲/۲ | بیمار | ۰/۰۱ | فلفل نمکی |

نتایج جدول (۱) نشان می‌دهد که روش ارائه شده‌ی ادغام فیلتر وینر و تبدیل موجک گسسته به خوبی می‌تواند نویزهای اضافه شده به تصویر را هم از نظر ظاهری و هم از نظر معیارهای ارزیابی حذف کند. روش ارائه شده نویزهای اسپکل و فلفل نمکی را نسبت به نویز گوسی بهتر حذف می‌کند و همچنین در تصاویر افراد سالم نسبت به افراد دارای بیماری رتینوپاتی دیابتی در تمامی موارد اضافه شدن نویز به تصویر بهتر حذف نموده است. در نهایت ابعاد تصویر را به 600×600 تبدیل کردیم تا تصویر حاصل مربعی، دارای ابعاد یکسان و کوچکتر باشد تا ادامه‌ی پردازش آسان‌تر شود.

۲-۲-۲- حذف نواحی نامطلوب تصویر

الگوریتم‌های خوشه‌بندی به‌طور خودکار ویژگی‌های متمایز کننده‌ی زیرگروه‌ها را تعریف می‌کنند و مدلی منحصر به فرد از روی روابط داده‌ها و همچنین از روی خوشه‌هایی که الگوریتم شناسایی می‌نماید، آموزش می‌دهند. خوشه‌بندی در واقع قرار دادن داده‌ها در گروه‌هایی است که اعضای گروه از زاویه‌ی خاصی به یکدیگر شباهت دارند و با اعضای خوشه‌های دیگر هیچ شباهتی ندارند یا حداقل نسبت به اعضای خوشه‌ی خود شباهت بسیار کمتری با اعضای دیگر خوشه‌ها دارند.

در این الگوریتم ابتدا k عضو (k تعداد خوشه هاست) به صورت تصادفی از میان n عضو به عنوان مراکز خوشه‌ها انتخاب می‌شوند سپس $n-k$ عضو باقیمانده هر کدام به نزدیکترین خوشه اختصاص می‌یابد. این کار با تعیین تابع هدف براساس میانگین فاصله‌ی اعضای هر خوشه نسبت به میانگین آنها عمل می‌کند و به شکلی نمونه‌ها را در داخل هر خوشه قرار می‌دهد که میانگین مجموع مربعات فاصله‌ها در خوشه‌ها، حداقل شود. سپس مراکز خوشه‌ها مجدداً محاسبه می‌گردند و ممکن است مراکز جدیدی برای خوشه‌ها انتخاب گردد. محاسبه و به‌روزر کردن مرکز خوشه‌ها از رابطه (۶) بدست می‌آید:

$$z^{k+1} = \frac{1}{|S_j^k|} \sum_{x \in S_j^k} x \quad (6)$$

Z مرکز خوشه‌ها و S_j زیر مجموعه‌های هر خوشه است. این کار تا زمانی که مراکز خوشه‌ها ثابت بماند، ادامه می‌یابد. شرط توقف از رابطه (۷) محاسبه می‌گردد [۱۷]:


$$\frac{1}{M} \sum \|z_j^k - z_j^{k+1}\| < th \quad (7)$$

در الگوریتم پیشنهادی در این مقاله تعداد خوشه‌ها ۲ قرار داده شد به این دلیل که تعداد ۲ خوشه تنها بخش‌های خیلی تاریک و خیلی روشن تصاویر (قسمت‌های خیلی تاریک مانند پیش‌زمینه و اطراف لبه‌ها و قسمت‌های خیلی روشن مانند دیسک - نوری) که در روند برنامه کاملاً بدون استفاده است را حذف می‌کند اما تعداد خوشه‌های بیشتر قسمتی از تصاویر را حذف می‌کنند که حاوی اطلاعاتی از قسمت‌های نشان‌دهنده‌ی عدم بیماری تصاویر است و در روند برنامه به آن احتیاج داریم. هدف استخراج ویژگی، هم استخراج ویژگی‌های سالم تصویر و هم استخراج ویژگی‌های بیمار تصویر است. به همین علت به تمام اطلاعات تصویر که نشان‌دهنده‌ی سالم یا بیمار بودن تصویر است، نیاز داریم.

داده‌ها بر اساس میزان تشابه در خوشه‌ها قرار می‌گیرند. معیارهای تشابه داده‌ها براساس معیار فاصله اقلیدسی است. فاصله اقلیدسی یکی از رایج‌ترین معیارهای تشابه است و از طریق رابطه‌ی (۸) محاسبه می‌گردد.


$$\text{Distance}(O_i, O_j) = \sqrt{\sum_{k=1}^m (x_{ik} - x_{jk})^2} \quad (8)$$

در این فرمول m تعداد ویژگی‌ها و x مقادیر ویژگی‌هاست. هرچه فاصله‌ی اقلیدسی کمتر باشد نشان‌دهنده‌ی تشابه بیشتر است. تعداد دفعاتی که خوشه بندی را با استفاده از موقعیت اولیه مرکز خوشه اولیه تکرار می‌کند برابر ۳ در نظر گرفته شده است. نتایج حاصل از خوشه‌بندی تصاویر را در تصویر (۹) مشاهده می‌کنید:



شکل (۹): تصویر فرد سالم خوشه بندی شده توسط K-means، (الف) تصویر حاصل از خوشه ۱، (ب) تصویر حاصل از خوشه ۲
Figure (9): Image of healthy person clustered by K-means, (a) Image of cluster 1, (b) Image of cluster 2

از این پس روی تصاویر حاصل از خوشه ۱ عملیات انجام می‌گردد و استخراج ویژگی‌ها از تصویر حاصل از خوشه ۱ انجام می‌گیرد. اگرچه در ظاهر تصویر بخش قابل‌ملاحظه‌ای از تصویر حذف نشده است ولی پیکسل‌های سیاه پیش‌زمینه تصویر و بخش‌های خیلی روشن تصویر حذف گردیده است، در واقع مقادیر پیکسل‌ها تغییر کرده است و این به دلیل وضوح بالای تصاویر پایگاه داده HRF است و روی تصاویر با وضوح پایین‌تر یا دارای نقاط تاریک و روشن بیشتر عملکرد خوشه‌بندی K-means بهتر نمایان شده و حجم تصویر حذف شده بسیار بیشتر است. در شکل (۱۰) نمونه‌ای از الگوریتم خوشه‌بندی K-means برای یک تصویر با وضوح پایین مشاهده می‌شود.



شکل (۱۰): تصویر فرد بیمار خوشه بندی شده توسط K-means دارای وضوح پایین، (الف) تصویر حاصل از خوشه ۱، (ب) تصویر حاصل از خوشه ۲

Figure 10: Single patient image clustered by K-means with low-resolution (a) Image of cluster 1, (b) Image of cluster 2

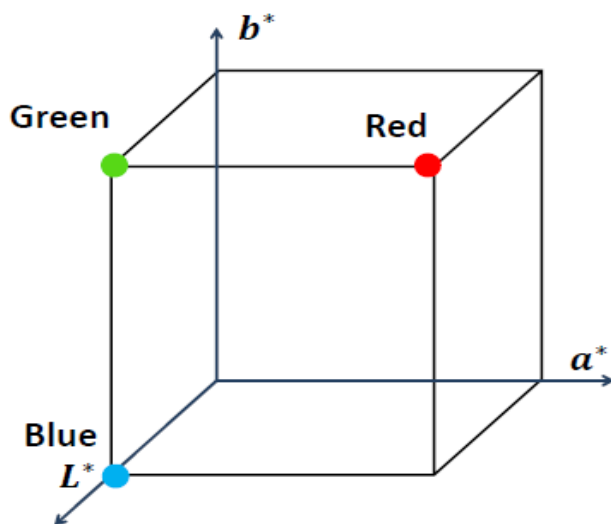
۳-۲- استخراج ویژگی

در مرحله‌ی بعد به استخراج ویژگی‌های شکل و رنگ از قسمت پس‌زمینه تصاویر شبکیه که توسط الگوریتم خوشه‌بندی k-means به آن دست‌یافتیم و در واقع بخش‌های بدون استفاده تصویر اصلی از آن حذف شده است می‌پردازیم. برای استخراج ویژگی‌های شکل تصاویر، بدین‌علت که ویژگی‌های رنگی تصاویر و کانال‌های مختلف فضای رنگ $l*a*b$ در مرحله‌ی قبل استخراج گردید، تصاویر را به تصاویر مقیاس‌خاکستری تبدیل کرده تا استخراج ویژگی‌های شکل آسان‌تر انجام شود و سپس ویژگی‌های شکل را استخراج می‌کنیم.

۱-۳-۲- استخراج ویژگی‌های رنگ تصاویر

برای استخراج ویژگی‌های رنگ تصاویر، تصاویر را به فضای رنگ $l^*a^*b^*$ برده و ویژگی‌های رنگ این سه کانال رنگی را استخراج می‌کنیم. فضای رنگی $l^*a^*b^*$ در مواردی که رنگ‌های تصویر در یک محدوده قرار دارد و بهم شبیه هستند عملکرد مناسب‌تری نسبت به سایر فضاها رنگی دارد. به همین دلیل چون تصاویر شبکه چشم دارای رنگ‌های بسیار شبیه هم است این فضای رنگی نسبت به فضای رنگی RGB برای استخراج ویژگی‌های رنگی بسیار مناسب‌تر و دارای نتایج بهتری است. فضای رنگی lab از سه زیر بخش تشکیل شده است. روشنایی^{۱۱} که می‌تواند عددی بین ۰ تا ۱۰۰ باشد ($L=0$ یعنی تاریکی کامل و $L=100$ یعنی روشنایی کامل). a که رنگ‌های بین قرمز و سبز است و می‌تواند عددی بین ۱۲۸- تا ۱۲۷+ باشد. مقادیر منفی نشان دهنده‌ی رنگ‌های سبز و مقادیر مثبت رنگ‌های قرمز را نشان می‌دهد. b که رنگ‌های بین زرد و آبی است و می‌تواند عددی بین ۱۲۸- تا ۱۲۷+ باشد. مقادیر منفی نشان دهنده‌ی رنگ‌های آبی و مقادیر مثبت رنگ‌های زرد را نشان می‌دهد [۱۸]. مدل فضای رنگی lab را در شکل (۱۱) می‌توان مشاهده کرد.

رنگ یکی از غالب‌ترین ویژگی‌های یک پیکسل است که در اغلب موارد در کنار سایر ویژگی‌هایی که برای تشخیص و طبقه‌بندی موضوع، مورد استفاده قرار می‌گیرد و اصولاً بسته به کاربرد یک فضای رنگی انتخاب شده، کانال‌های رنگی آن استخراج می‌گردد و از آن پس می‌توان بدون در نظر گرفتن رنگ تصاویر پردازش انجام گیرد تا حجم محاسبات کاهش یابد. مجموع ویژگی‌های رنگی تصاویر به دست آمده از سه کانال رنگ l, a, b یک ماتریس سه بعدی با ابعاد ۲۳۱۲×۳۴۸۸ است.



شکل (۱۱): مدل فضای رنگ $l^*a^*b^*$ [۱۸]
Figure (11): Color space model $l^* a^* b^*$ [18]

۲-۳-۲- استخراج ویژگی‌های شکل تصاویر

برای استخراج ویژگی‌های شکل نیازی به تصاویر پر حجم رنگی نیست پس ابتدا تصاویر رنگی را به تصاویر مقیاس خاکستری تبدیل کرده تا حجم محاسبات به میزان قابل توجهی کاهش یابد سپس ویژگی‌های شکل تصاویر را استخراج می‌کنیم. به منظور استخراج ویژگی‌های شکل مجموعه تصاویر از هر تصویر ۱۲ گروه ویژگی استخراج می‌شود که برخی از این ویژگی‌ها خود شامل چندین زیر ویژگی است به این صورت که خود ویژگی نیز با یک ماتریس $m \times n$ تعریف شده اند. در مجموع بعد از انجام یک سری عملیات و قرار دادن ویژگی‌ها در کنار هم یک ماتریس ۱۳×۲۱۶ از ویژگی‌ها ایجاد می‌گردد که در ادامه برای طبقه‌بندی تصاویر از این ماتریس استفاده می‌شود. ویژگی‌های شکل استخراج شده از تصاویر به شرح زیر است:

- گریز از مرکز^{۱۲}: گریز از مرکز در واقع اندازه گیری نسبت اعداد است. این نسبت طول محو اصلی به طول محو فرعی است که با ۲ روش محو اصلی یا روش حداقل مستطیل محدود محاسبه می‌گردد.

الف) روش محور اصلی: محورها اصلی به عنوان دویخشی که در مرکز یکدیگر را قطع می‌کنند منحصر به فرد است. ماتریس کواریانس C یک کانتور را در نظر بگیرید:

$$C = \frac{1}{N} \sum_{i=0}^{N-1} \begin{pmatrix} x_i - g_x \\ y_i - g_y \end{pmatrix} \begin{pmatrix} x_i - g_x \\ y_i - g_y \end{pmatrix}^T = \begin{pmatrix} c_{xx} & c_{xy} \\ c_{yx} & c_{yy} \end{pmatrix} \quad (9)$$

که

$$C_{xx} = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - g_x)^2 \quad (10)$$

$$C_{xy} = C_{yx} = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - g_x)(y_i - g_y) \quad (11)$$

$$C_{yy} = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - g_y)^2 \quad (12)$$

طول دو محور اصلی برابر با مقادیر ویژه λ_1 و λ_2 است [20]:

$$\det(C - \lambda_{1,2} I) = 0 \quad (13)$$

پس

$$\lambda_{1,2} = \frac{1}{2} [C_{xx} + C_{yy} \pm \sqrt{(C_{xx} + C_{yy})^2 - 4(C_{xx}C_{yy} - C_{xy}^2)}] \quad (14)$$

در نتیجه:

$$E = \frac{\lambda_2}{\lambda_1} \quad (15)$$

ب) روش حداقل مستطیل محدود: کوچک‌ترین مستطیل در برگزیده شکل را مطابق رابطه (16) بدست می‌آوریم:

$$E = 1 - \frac{W}{L} \quad (16)$$

که W ضلع کوچک مستطیل و L ضلع بزرگ مستطیل است و در شکل (12) به خوبی نمایش داده شده است.



شکل (12): روش حداقل مستطیل محدود [20]

Figure (12): Finite Rectangular Minimum Method [20]

در هر دو روش اعداد بدست آمده بین 0 و 1 قرار دارد که 0 نشان‌دهنده دایره و 1 نشان‌دهنده یک خط است [19].
- عدد اویلر¹³: عدد اویلر رابطه بین تعداد قطعات مجاور و تعداد حفره‌های شکل را بیان می‌کند. اگر S تعداد قطعات مجاور و N تعداد حفره‌های شکل باشد عدد اویلر از رابطه (17) بدست می‌آید [20]:

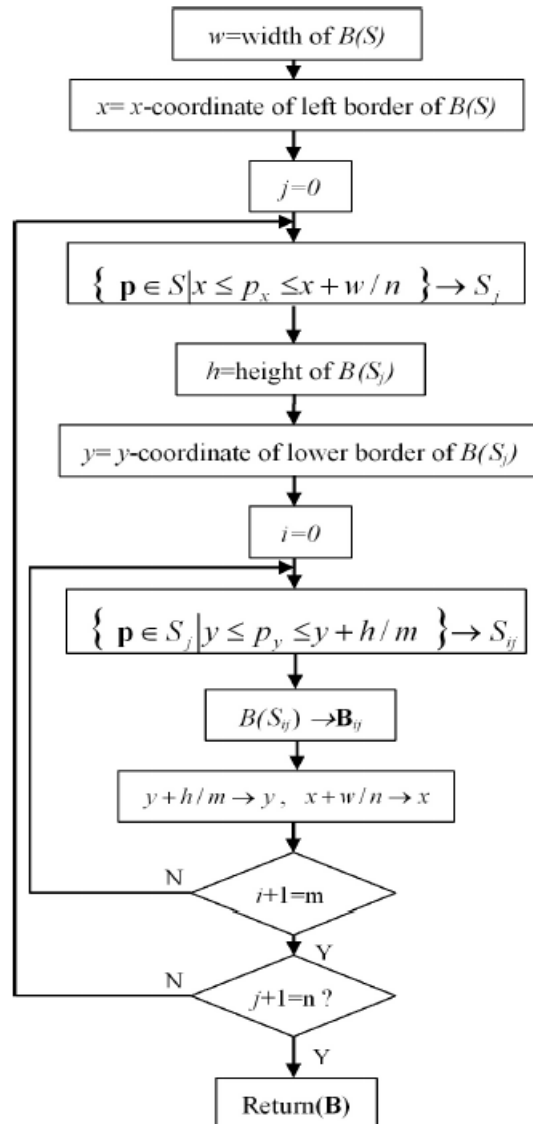
$$Eul = S - N \quad (17)$$

- جعبه محدود¹⁴: برخلاف بسیاری از روش‌های دیگر به اشکال وابسته نیست و به توپولوژی‌های دلخواه اعمال می‌شود. پس از نرمال‌سازی، یک شکل S مجموعه‌ای از پیکسل‌های L است که معمولاً به صورت رابطه (18) نوشته می‌شود:

$$|S| = L \quad (18)$$


حداقل مستطیل مرزی یا جعبه محدود S با $B(s)$ نمایش داده می‌شود که H و W به ترتیب عرض و ارتفاع مستطیل است. شکل (۱۳) فلوچارت تقسیم یک شکل را به m سطر و n ستون و شکل (۱۴) مراحل تقسیم‌بندی یک شکل توسط جعبه محدود را نشان می‌دهد [۲۰].

- منطقه یا ناحیه: یک تابع منطقه است که می‌تواند به‌عنوان نمایه شکل مورد استفاده قرار گیرد.
- Perimeter: فاصله‌ی اطراف مرز در منطقه محدود شده را نشان می‌دهد.
- Convex Area: تعداد قسمت‌های محدب تصویر را نمایش می‌دهد.



شکل (۱۳): فلوچارتی از تقسیم شکل با جعبه محدود [۲۰]

Figure (13): Flowchart of Shaped Box Split Shape [20]




شکل (۱۴): مراحل تقسیم بندی یک شکل توسط جعبه محدود را نشان می دهد. (a) جعبه محدود B(s) را برای پیکسل های S نشان می دهد. (b) تقسیم S به n قسمت عمودی، (c) جعبه محدود B(S_j) را برای پیکسل های عمودی محاسبه شده است. (d) تقسیم شکل حاصل از مرحله قبل به m قسمت افقی. (e) محاسبه B(S_{ij}) برای کل شکل [۲۰]
 Figure (14) shows the steps of dividing a shape by a finite box. (a) shows the bounding box B (s) for the pixels S. (B) Splits S into n vertices (c) (c) The bounded box B(S_j) is calculated for the vertical pixels. (d) Splits the figure from the previous step into m horizontal section. (e) Calculates B(S_{ij}) for the whole figure [19]

- استحکام^{۱۵}: نشان می دهد که شکل محدب یا مقعر است و با رابطه (۱۹) مشخص می شود:

$$\text{Soldity} = \frac{A_s}{H} \quad (19)$$

که A_s منطقه شکل H و منطقه محدب شکل است. استحکام شکل محدب همیشه ۱ است [۲۱].
 - Extrema: هشت نقطه افراطی تصویر را نشان می دهد که شامل بالاچپ، چپ بالا، چپ پایین، پایین چپ، بالا راست، راست پایین، پایین راست، راست بالا است.



شکل (۱۵): ۸ نقطه افراطی تصویر
 Figure (15): 8 extreme points of the image

- Equiv Diameter: قطر دایره ای که دربرگیرنده پیکسل های مشابهی از منطقه است را نمایش می دهد که از رابطه (۲۰) محاسبه می گردد:

$$\text{EquivDiameter} = \sqrt{\frac{4 * \text{Area}}{\pi}} \quad (20)$$

- Major Axis Length: طول محورا اصلی بیضی را که دارای لحظات مرکزی دوم عادی مشابه است به عنوان منطقه مشخص می کند.

- Minor Axis Length: طول محور فرعی بیضی را که دارای لحظات مرکزی دوم عادی مشابه است به عنوان منطقه مشخص می کند.

- Orientation: زاویه ی بین محور اصلی بیضی و خط افق را نمایش می دهد به عبارت دیگر نشان دهنده جهت گیری بیضی را است.

که Area نشان‌دهنده‌ی تعداد واقعی پیکسل‌های منطقه مورد نظر است.

۳-۲-۳- کاهش بعد ویژگی‌ها

به این علت که مجموع ویژگی‌های شکل و رنگ بدست آمده ماتریس‌های بسیار بزرگی هستند و انجام پردازش و طبقه‌بندی توسط این مجموعه ویژگی بزرگ کار بسیار مشکلی است، به‌منظور کاهش بعد، ویژگی‌های شکل و رنگ را به الگوریتم کارآمد تجزیه و تحلیل مولفه‌های اصلی^{۱۶} (PCA) می‌دهیم. یکی از رایج‌ترین روش‌های آماری به‌منظور کاهش ابعاد داده‌ها روش تجزیه و تحلیل مولفه‌های اصلی است. تجزیه و تحلیل مولفه‌های اصلی به ما کمک می‌کند تا به‌جای اینکه تمام ویژگی‌ها را مورد بررسی قرار دهیم. با محاسبه واریانس ویژگی‌ها، ویژگی‌هایی که بیشترین مقدار واریانس یا به عبارتی بیشترین مقدار انرژی را دارد وارد فضای جدیدی کرده و از این پس از آنها استفاده کنیم [۱۷]. این روش از مقادیر ویژه، بردارهای ویژه و ماتریس کواریانس داده‌ها استفاده می‌کند.

الگوریتم تجزیه و تحلیل مولفه‌های اصلی:

- محاسبه میانگین

$$\mu = \frac{\sum_{i=1}^n x_i}{n} \quad (21)$$

- انحراف معیار استاندارد

$$S = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{(n-1)}} \quad (22)$$

- واریانس داده‌ها برابر توان دوم انحراف معیار است.

- کواریانس داده‌ها: ماتریس کواریانس یک ماتریس متقارن است با فرض اینکه ابعاد داده‌ها n باشد ماتریس کواریانس، یک ماتریس مربعی n×n است. که از رابطه (۲۳) محاسبه می‌شود.

$$\text{cov}(x,y) = \frac{\sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y)}{n-1} \quad (23)$$

- محاسبه مقادیر ویژه

$$|\text{Cov}(x,y) - \lambda_i I| = 0 \quad (24)$$

- محاسبه بردارهای ویژه: یک ماتریس کواریانس n×n دارای n بردار ویژه است که از رابطه (۲۵) بدست می‌آید.

$$\text{Cov}(x,y) \times v_i = \lambda_i v_i \quad (25)$$

- بعد از محاسبه بردارهای ویژه و مقادیر ویژه، مقادیر ویژه را به‌صورت نزولی مانند رابطه (۲۶) مرتب می‌کنیم:

$$\lambda_1 > \lambda_2 > \lambda_3 \dots > \lambda_{n-1} > \lambda_n \quad (26)$$

- بدست آوردن مقدار k: مقدار k در واقع کوچکترین عددی است که عبارت نامساوی زیر را برقرار می‌کند. انتخاب k به گونه‌ای که رابطه (۲۷) را برقرار کند بدین معناست که ۹۵ درصد خصوصیات داده‌ها را حفظ کرده ایم [۱۷].

$$\frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i} \leq 0.95 \quad (27)$$

- بدست آوردن داده‌های جدید:

$$D_{\text{new}} = V^T \times D_{\text{original}} \quad (28)$$

به کمک تجزیه و تحلیل مولفه‌های اصلی مجموعه ویژگی‌های شکل به یک ماتریس ۱۳×۱۳ تبدیل شده است به عبارتی ۲۸۰۸ ویژگی شکل را با کمک PCA به ۱۶۹ ویژگی تبدیل کرده‌ایم و مجموعه ویژگی‌های رنگ به ۳ ماتریس ۱۷×۱۷ تبدیل شده است، به عبارتی ۳ ماتریس ویژگی‌های رنگ که هر ماتریس ۸۰۶۴۲۵۶ ویژگی رنگی را دربرداشت به ۳ ماتریس که هر کدام ۲۸۹ ویژگی رنگی را دربردارد تبدیل شده است.

۴-۲- طبقه‌بندی داده‌ها با ماشین بردار پشتیبان

در آخرین مرحله از روند تشخیص تصاویر افراد سالم از تصاویر افراد بیمار ویژگی‌هایی که توسط تجزیه و تحلیل مولفه‌های اصلی به‌عنوان بهترین ویژگی‌ها انتخاب شده است را برای عمل طبقه‌بندی در اختیار ماشین بردار پشتیبان قرار می‌دهیم تا تصمیم بگیرد که کدام تصویر یک فرد سالم و کدام تصویر یک فرد بیمار است. طبقه‌بند ماشین بردار پشتیبان^{۱۷} (SVM) از بهترین الگوریتم‌های طبقه‌بندی به‌شمار می‌رود و برای داده‌های خطی، غیرخطی، دوکلاسه و چند کلاسه می‌توان از آن بهره برد.

به‌طور خلاصه، الگوریتم‌های ماشین بردار پشتیبان به کمک یک نگاشت غیرخطی فضای داده‌های آموزشی را به یک بعد بالاتر می‌برد و سپس در این بعد جدید به دنبال ابرصفحه‌ای است که نمونه‌های یک کلاس را از کلاس‌های دیگر جدا کند. یک الگوریتم ماشین بردار پشتیبان به دنبال ابرصفحه‌ای است که حداکثر حاشیه را ایجاد کند، ابرصفحه‌ای با حاشیه‌ی بیشتر، دقت بیشتری را نیز در طبقه‌بندی داده‌ها آموزشی ایجاد می‌کند. حاشیه در واقع دو برابر فاصله‌ی ابرصفحه و نزدیک‌ترین نمونه‌های آموزشی است [۱۷].

برای طبقه‌بندی داده‌ها ابتدا ویژگی‌های رنگ و شکل تصاویر را که در مراحل قبل در کنار هم در یک ماتریس قرار داده بودیم را برای تمامی تصاویر استخراج می‌کنیم. سپس از ۳۰ مجموعه ویژگی بدست آمده‌ی حاصل از ۳۰ تصویر پایگاه داده که شامل ۱۵ تصویر سالم و ۱۵ تصویر بیمار است به‌طور تصادفی ۱۰ تصویر که شامل ۵ تصویر سالم و ۵ تصویر بیمار است برای آزمایش و ۲۰ تصویر که شامل ۱۰ تصویر سالم و ۱۰ تصویر بیمار است، برای آموزش طبقه‌بند ماشین بردار پشتیبان استفاده می‌کنیم. قابل توجه است که مجموعه تصاویر آموزش و تست به‌صورت تصادفی انتخاب می‌شوند. مشخصات و نتایج کرنل‌های مختلف و روش‌های مورد استفاده برای هر کرنل طبقه‌بند ماشین بردار پشتیبان که در این پژوهش مورد آزمایش قرار گرفته است، در جدول (۲) ذکر شده است.

۳- ارزیابی الگوریتم پیشنهادی

به‌منظور ارزیابی الگوریتم پیشنهادی برای تشخیص سالم یا بیمار بودن تصاویر فوندوس شبکیه از بیماری رتینوپاتی دیابتی معیارهای کمی زیر معرفی شده است:

- نرخ مثبت بودن درست (TPR): نشان‌دهنده تعداد تصاویر افراد بیمار است که به درستی بیمار تشخیص داده شده است.
- نرخ مثبت بودن نادرست (FPR): نشان‌دهنده تعداد تصاویر افراد سالم که به اشتباه بیمار تشخیص داده شده است.
- نرخ منفی بودن نادرست (TNR): نشان‌دهنده تعداد تصاویر افراد سالم که به‌درستی سالم تشخیص داده شده است.
- نرخ منفی بودن نادرست (FNR): نشان‌دهنده تعداد تصاویر افراد بیمار که به اشتباه بیمار تشخیص داده شده است.

با توجه به معیارهای ذکر شده دقت، حساسیت و صحت به‌صورت زیر تعریف می‌گردند:

- صحت^{۱۸}: صحت معیاری توصیفی از خطاهای ذاتی اندازه‌گیری در نظر می‌گیرند که از رابطه (۲۹) و با توجه به تعاریف معیارهای TPR و FPR محاسبه می‌گردد.

$$\text{Precision} = \frac{\text{TPR}}{\text{FPR} + \text{TPR}} \quad (29)$$

- حساسیت^{۱۹}: از رابطه (۳۰) و با توجه به تعاریف معیارهای TPR و FNR محاسبه می‌شود.

$$\text{Sensitivity} = \frac{\text{TPR}}{\text{TPR} + \text{FNR}} \quad (30)$$

- دقت^{۲۰}: دقت نشان‌دهنده پراکندگی آماری داده‌ها است که از رابطه (۳۱) و با توجه به تعاریف معیارهای TPR، FPR، TNR و FNR محاسبه می‌گردد.

$$\text{Accuracy} = \frac{\text{TPR} + \text{TNR}}{\text{TPR} + \text{TNR} + \text{FPR} + \text{FNR}} \quad (31)$$

بررسی طبقه‌بندی داده‌ها توسط معیارهای ارزیابی ذکرشده را می‌توان در جدول (۲) مشاهده نمود.

Table (2): Results of the different kernels and the methods used for each SVM Classifier kernel
 جدول (۲) : مشخصات و نتایج کرنل‌های مختلف و روش‌های مورد استفاده برای هر کرنل طبقه بند SVM

| ردیف | نام کرنل | متد | دقت آموزش | دقت آزمایش | حساسیت آزمایش | صحت آزمایش | TPR | FPR | TNR | FNR |
|------|------------------|------|-----------|------------|------------------|---------------|-----|-----|-----|-----|
| ۱ | کرنل خطی | SMO | ٪۱۰۰ | ٪۹۰ | ٪۸۰ | ٪۱۰۰ | ۴ | ۰ | ۵ | ۱ |
| ۲ | کرنل خطی | ISDA | ٪۹۵ | ٪۷۰ | ٪۴۰ | ٪۰ | ۲ | ۰ | ۵ | ۳ |
| ۳ | کرنل خطی | QP | ٪۱۰۰ | ٪۷۰ | ٪۸۰ | ٪۶۶/۷ | ۲ | ۲ | ۳ | ۱ |
| ۴ | کرنل خطی | LS | ٪۱۰۰ | ٪۷۰ | ٪۸۰ | ٪۶۶/۷ | ۴ | ۲ | ۳ | ۱ |
| ۵ | کرنل چند جمله‌ای | SMO | ٪۱۰۰ | ٪۶۰ | ٪۴۰ | ٪۶۶/۷ | ۲ | ۱ | ۴ | ۳ |
| ۶ | کرنل چند جمله‌ای | ISDA | ٪۱۰۰ | ٪۵۰ | ٪۶۰ | ٪۶۶/۷ | ۳ | ۳ | ۲ | ۱ |
| ۷ | کرنل چند جمله‌ای | QP | ٪۱۰۰ | ٪۵۰ | ٪۱۰۰ | ٪۵۰ | ۵ | ۵ | ۰ | ۰ |
| ۸ | کرنل چند جمله‌ای | LS | ٪۱۰۰ | ٪۵۰ | ٪۱۰۰ | ٪۵۰ | ۵ | ۵ | ۰ | ۰ |
| ۹ | کرنل گوسین | SMO | ٪۱۰۰ | ٪۶۰ | ٪۴۰ | ٪۶۶/۷ | ۲ | ۱ | ۴ | ۳ |
| ۱۰ | کرنل گوسین | ISDA | ٪۱۰۰ | ٪۵۰ | ٪۰ | ٪۰ | ۰ | ۰ | ۵ | ۵ |
| ۱۱ | کرنل گوسین | QP | ٪۱۰۰ | ٪۵۰ | ٪۰ | ٪۰ | ۰ | ۰ | ۵ | ۵ |
| ۱۲ | کرنل گوسین | LS | ٪۱۰۰ | ٪۵۰ | ٪۰ | ٪۰ | ۰ | ۰ | ۵ | ۵ |
| ۱۳ | کرنل MLP | SMO | ٪۱۰۰ | ٪۷۰ | ٪۶۰ | ٪۷۵ | ۳ | ۱ | ۴ | ۲ |
| ۱۴ | کرنل MLP | LS | ٪۱۰۰ | ٪۷۰ | ٪۸۰ | ٪۶۶/۷ | ۴ | ۲ | ۳ | ۱ |
| ۱۵ | کرنل درجه دوم | SMO | ٪۱۰۰ | ٪۶۰ | ٪۱۰۰ | ٪۵۵/۶ | ۵ | ۴ | ۱ | ۰ |
| ۱۶ | کرنل درجه دوم | QP | ٪۱۰۰ | ٪۶۰ | ٪۱۰۰ | ٪۵۵/۶ | ۵ | ۴ | ۱ | ۰ |
| ۱۷ | کرنل درجه دوم | LS | ٪۱۰۰ | ٪۶۰ | ٪۱۰۰ | ٪۵۵/۶ | ۵ | ۴ | ۱ | ۰ |

۴- بحث و نتیجه‌گیری

نتایج کرنل‌های مختلف و روش‌های مورد استفاده برای هر کرنل طبقه‌بند ماشین بردار پشتیبان را می‌توان در جدول (۲) به‌طور کامل مشاهده کرد. از جدول (۲) می‌توان به نکات زیر پی‌برد:

✓ بهترین نتیجه از بین کرنل‌های متفاوت و روش‌های متفاوت هریک برای کرنل خطی با روش SMO است که دقت تصاویر آموزشی برابر ٪۱۰۰ و دقت تصاویر آزمایش برابر ٪۹۰ را از خود نشان داده است و تنها یک تصویر بیمار به اشتباه سالم طبقه‌بندی شده است.

✓ روش SMO برای تمامی کرنل‌های مورد آزمایش بهترین نتایج را دربرداشته است، در بعضی موارد از سایر روش‌ها بالاتر و در بعضی موارد یکسان با آنها عمل کرده است.

✓ دقت تصاویر آموزش برای تمامی کرنل‌ها و روش‌های آنها برابر ٪۱۰۰ نشان داده شده است به جز کرنل خطی با روش ISDA که دقت تصاویر آموزشی را برابر ٪۹۵ نشان داده است و تنها یک تصویر را به اشتباه طبقه‌بندی کرده است.

✓ پایین‌ترین دقت نتایج تصاویر تست برای کرنل‌های گوسین و چندجمله‌ای است که دقتی بین ٪۵۰ تا ٪۶۰ را از خود نشان داده‌اند و مشخص است کرنل‌های ذکر شده عملکرد مناسبی برای این مجموعه تصویر و ویژگی‌های استخراج شده برای هر تصویر را ندارند. البته کرنل گوسی تمامی تصاویر بیمار را به‌درستی طبقه‌بندی کرده است ولی تصاویر افراد سالم را نتوانسته به‌درستی طبقه‌بندی کند.

✓ روش‌های متفاوت کرنل‌ها در اکثر موارد صحت یکسانی نسبت به هم از خود نشان داده‌اند (به جز روش SMO که اصولاً دقت بالاتری داشته است) ولی در بعضی موارد در بین تشخیص‌های درست یا نادرست آنها تعداد افراد سالم و بیمار متفاوت است مانند روش SMO و LS برای کرنل MLP که تعداد افراد سالم و بیمار در تشخیص‌های درست و نادرست آن متفاوت است.

References

مراجع

- [1] S. Ali, "The survey of method base on training and electronic learning for early detection of retinal hemorrhages in diabetic retinopathy", *Interdisciplinary Journal of Virtual Learning in Medical Sciences*, vol. 5, no. 1, pp. 77-87, April 2014.
- [2] A. W. Reza, C. Eswaran, "A decision support system for automatic screening of non-proliferative diabetic retinopathy", *Journal of Medical Systems*, vol. 35, no 1, pp.17-24, Feb. 2011 (doi: 10.1007/s10916-009-9337-y).
- [3] M. Sona, F. Amin, "Feature extraction and intelligent detection of diabetic retinopathy in retinal images", *Proceeding of the NCESD*, May 2016 (in Persian)
- [4] J. Amin, M. Sharif, M. Yasmin, H. Ali, S.L. Fernandes, "A method for the detection and classification of diabetic retinopathy using structural predictors of bright lesions", *Journal of Computational Science*, vol. 19, pp.153-64, March 2017 (doi: 10.1016/j.jocs.2017.01.002).
- [5] X. Zhang, G. Thibault, E. Decencièrè, B. Marcotegui, B. Lay, R. Danno, G. Cazuguel, G. Quellec, M. Lamard, P. Massin, A. Chabouis, Z. Victor, A. Erginay, "Exudate detection in color retinal images for mass screening of diabetic retinopathy", *Medical Image Analysis*, vol. 18, no. 7, pp. 1026-1043, Oct. 2014 (doi: 10.1016/j.media.2014.05.004).
- [6] N. G. Ranamuka, R. G. N. Meegama, "Detection of hard exudates from diabetic retinopathy images using fuzzy logic", *IET Image Processing*, vol. 7, no. 2, pp. 121-130, March 2013 (doi: 10.1049/iet-ipr.2012.0134).
- [7] I. Lazar, A. Hajdu, "Retinal microaneurysm detection through local rotating cross-section profile analysis", *IEEE Trans. on Medical Imaging*, vol. 32, no. 2, pp. 400-407, Feb. 2013 (doi: 10.1109/TMI.2012.2228665).
- [8] L. Tang, M. Niemeijer, J. M. Reinhardt, M. K. Garvin, M. D. Abramoff, "Splat feature classification with application to retinal hemorrhage detection in fundus images", *IEEE Trans. on Medical Imaging*, vol. 32, no. 2, pp. 364-375, Feb. 2013 (doi: 10.1109/TMI.2012.2227119).
- [9] E. Imani, H.-R. Pourreza, T. Banaee, "Fully automated diabetic retinopathy screening using morphological component analysis", *Computerized Medical Imaging and Graphics*, vol. 43, pp. 78-88, July 2015.
- [10] L. Seoud, T. Hurtut, J. Chelbi, F. Cheriet, J. P. Langlois, "Red lesion detection using dynamic shape features for diabetic retinopathy screening", *IEEE Trans. on medical imaging*, vol. 35, no. 4, pp. 1116-1126, Dec. 2015 (doi: 10.1109/TMI.2015.2509785).
- [11] M. E. Gegundez-Arias, D. Marin, B. Ponte, F. Alvarez, J. Garrido, C. Ortega, M. J. Vasallo, J. M. Bravo, "A tool for automated diabetic retinopathy pre-screening based on retinal image computer analysis", *Computers in Biology and Medicine*, vol. 88, pp. 100-109, Sept. 2017 (doi: 10.1016/j.compbiomed.2017.07.007).
- [12] M. K. Behera, S. Chakravarty, "Diabetic retinopathy image classification using support vector machine", *Proceeding of the IEEE/ICCSEA*, pp. 1-4, Gunupur, India, March 2020 (doi: 10.1109/ICCSEA49143.2020.9-132875).
- [13] High Resolution Fundus Retinal Image Database: <https://www5.cs.fau.de/research/data/fundus-images/>.
- [14] H.-H. Tsai, Y.-J. Jhuang, Y.-S. Lai, "An SVD-based image watermarking in wavelet domain using SVR and PSO", *Applied Soft Computing*, vol. 12, no. 8, pp. 2442-2453, Aug. 2012 (doi: 10.1016/j.asoc.2012.02.021).
- [15] N. Ehsan, S. Sara, "Reduction of image spectral noise using diffusion equations and pixone image concept", *Amirkabir University of Technology (Tehran Polytechnic)*, March 2008 (in Persian).
- [16] A. Somayeh, G. Mohammad, D. Vali, "A new hybrid fuzzy intelligent filter for medical image noise reduction", *Computational Intelligence in Electrical Engineering*, vol 5, no 3, pp.47-54, 2015 (in Persian).
- [17] E. Mehdi, "Data mining concepts and techniques", *Knowledge Need*, 2014 [online].
- [18] V. S. Rathore, M. S. Kumar, A. Verma, "Colour based image segmentation using $L^* a^* b^*$ colour space based on genetic algorithm", *International Journal of Emerging Technology and Advanced Engineering*, vol. 2, no. 6, pp. 156-162, June 2012.
- [19] F. Garcia-Lamont, J. Cervantes, A. López, L. Rodriguez, "Segmentation of images by color features: A survey", *Neurocomputing*, vol. 292, pp. 1-27, May 2018 (doi: 10.1016/j.neucom.2018.01.091).
- [20] M. Yang, K. Kpalma, J. Ronsin, "A survey of shape feature extraction techniques", ed: InTech, Nov 2008.
- [21] C. Chang, W. Liu, H. Zhang, "Image retrieval based on region shape similarity", *Storage and Etrieval for Media Databases 2001, 2001*, vol. 4315: International Society for Optics and Hotonics, pp. 31-38.

زیر نویس ها

1. Microaneurysm
2. Exudate
3. Hemorrhage

4. Gabor filter
5. Adaptive pattern
6. Toboggan Algorithm
7. Watershed Algorithm
8. Morphological Component Analysis(MCA)
9. Scale Invariant Feature Transform(SIFT)
10. Speeded Up Robust Features(SUFR)
11. Lightness
12. Eccentricity
13. Euler number
14. Bounding Box
15. Solidity
16. Principal Component Analysis
17. Support Vector Mashin
18. Precision
19. Sensivity
20. Accuracy