



Diagnosis of MS from OCT Images Using Machine Learning Algorithms and Improving Accuracy by Combining Different Classifiers

1 Maryam Aboutalebian, *2 Nasrindokht Batenipour

Author Affiliations:

1. Department of Biomedical Engineering, NT.C., Islamic Azad University, Tehran, Iran
2. *Department of Electrical Engineering, NT.C., Islamic Azad University, Tehran, Iran

Key words:

Multiple Sclerosis
Machine Learning
OCT
Confusion Matrix

Abstract

Given the importance of maintaining the health of personnel in high-risk environments (such as space missions) and the need to improve health monitoring systems in the aerospace electrical and electronic engineering industries, this study focuses on multiple sclerosis (MS). For disease diagnosis, the Johns Hopkins Hospital database was used, containing optical coherence tomography (OCT) images of the right retina from 35 subjects (21 MS patients and 14 healthy individuals) collected over a 10-year period. After preprocessing the images and extracting relevant features, three different classifiers were applied to categorize the subjects into healthy and MS groups. Confusion matrices were obtained for the Random Forest (RF), Support Vector Machine (SVM), and K-Nearest Neighbors (KNN) classifiers, and the classification accuracy for each was calculated. The results showed that the RF classifier achieved the highest accuracy (85%), while KNN had the lowest (57%). The SVM classifier achieved an accuracy of 71%. Finally, a hybrid ensemble method based on majority voting was applied to combine the predictions of the three classifiers. The results indicated that by integrating the classifiers, an overall accuracy of 91% could be achieved. These findings are consistent with those reported in recent similar studies.

* Corresponding author E-mail: NdBatani@iau.ir



تشخیص بیماری ام‌اس از روی تصاویر OCT با استفاده از الگوریتم‌های یادگیری ماشین و بهبود دقت با ترکیب طبقه بندهای مختلف

مریم ابوطالبیان^۱، نسرين دخت باطنی پور^{۲*}

۱- گروه مهندسی پزشکی، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران، maryam.aboutalebian@iau.ir

۲- گروه مهندسی برق، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران، NdBateni@iau.ir، batenind@gmail.com

واژگان کلیدی

چکیده

با توجه به اهمیت سلامتی کارکنان در شرایط پرخطر (مانند مأموریت‌های فضایی) و ضرورت بهبود سامانه‌های نظارت بر سلامت در صنایع حوزه مهندسی برق و الکترونیک هوافضا، در این تحقیق بیماری مولتیپل اسکلروزیس (ام‌اس) مورد بررسی قرار گرفته است. برای تشخیص این بیماری از پایگاه داده بیمارستان جانز هاپکینز استفاده شد که حاوی تصاویر توموگرافی انسجام نوری (OCT) از شبکه چشم راست ۳۵ نفر (۲۱ بیمار مبتلا به ام‌اس و ۱۴ فرد سالم) در طول مدت ۱۰ سال است. پس از پیش پردازش تصاویر و استخراج ویژگی‌ها، از سه طبقه بند مختلف جهت دسته بندی افراد در دو گروه سالم و بیمار استفاده شد. ماتریس درهم ریختگی برای سه طبقه بند جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و K-نزدیکترین همسایه (KNN) استخراج و دقت تشخیص بیماری برای هریک محاسبه گردید. نتایج نشان داد طبقه بند RF با دقت ۸۵٪ بیشترین دقت و KNN با ۵۷٪ کمترین دقت را دارد. طبقه بند SVM به دقت ۷۱٪ رسید. در نهایت با استفاده از روش‌های ترکیبی پیشبینی آنها به کمک رأی اکثریت ادغام گردید. نتایج نشان داد که با ترکیب این سه طبقه بند می‌توان به دقت ۹۱٪ رسید. این دقت‌ها با نتایج مطالعات مشابه اخیر مطابقت دارد.

مولتیپل اسکلروزیس
یادگیری ماشین
توموگرافی انسجام نوری
ماتریس درهم ریختگی

پژوهش های نوین در مهندسی برق و الکترونیک هوایی، فصل ۲ شماره ۱، پاییز ۱۴۰۴ مطالعاتی که در این زمینه انجام شدند روش هایی را برای تقسیم بندی خودکار لایه های ماکولا و مقایسه ویژگی های لایه های عصبی در تصاویر OCT ارائه کردند و از این اطلاعات برای تشخیص بیماری استفاده نمودند. [۴، ۵] برخی تحقیقات برای تشخیص زودهنگام بیماران ام اس از اندازه گیری ضخامت لایه فیبرهای عصبی شبکه در تصاویر OCT استفاده نمودند. [۶] نتایج تحقیقات نشان داد که تصاویر OCT در کنار سایر تست های بالینی نقش مهمی در تشخیص شدت بیماری های مرتبط با از بین رفتن عصب از جمله بیماری ام اس دارند. [۷] جهت استخراج ویژگی های تصاویر OCT می توان از الگوریتم های مختلف یادگیری ماشین و شبکه های عصبی استفاده نمود. [۱۴-۸]

در این تحقیق، به بررسی روش های تشخیص بیماری ام اس با استفاده از تکنیک های OCT می پردازیم و سپس با استفاده از یادگیری ماشین، دقت تشخیص بیماری را افزایش می دهیم. همچنین می توان از این روش برای تشخیص بیماری از راه دور توسط پزشک استفاده نمود. بهره وران این پروژه می توانند کلیه ی سازمان های پزشکی و پزشکان درگیر با تشخیص و درمان بیماری ام اس باشند. علاوه بر آن سازمان های غیر پزشکی که این بیماری در عملکرد شغلی آنها اختلال ایجاد می کند نیز می توانند جهت تشخیص زودهنگام بیماری از این پروژه بهره برداری کنند. نتایج این تحقیق در بهبود عملکرد و طراحی بهینه سامانه های نظارت سلامت در شرایط پرخطر (مانند مأموریت های فضایی)، در حوزه مهندسی برق و الکترونیک هوافضا اهمیت ویژه ای دارد.

بدین منظور، در بخش های بعدی پس از بیان روش اجرای تحقیق، مرا حل استخراج ویژگی و طبقه بندی داده ها با استفاده از روش های جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، نزدیک ترین هم سایه (KNN) و ترکیب آنها بررسی میشود.

۲- روش تحقیق

در این تحقیق از دیتاهای موجود در پایگاه های داده وب سایت بیمارستان جانز هاپکینز استفاده می شود و مطالعه مقطعی و مطالعه طولی بر روی آنها انجام می شود. در مطالعه مقطعی تعدادی بیمار ام اس (شامل زن و مرد) و تعدادی فرد سالم (شامل زن و مرد) مورد مطالعه قرار می گیرند. در مطالعه طولی بیماران ام اس در چندین ویزیت تا تکمیل پیگیری ۱۰ ساله مورد ارزیابی قرار می گیرند. شرکت کنندگان هیچ بیماری چشمی یا هیچ سابقه آسیب شناسی شبکه یا شرایط سامانه ای که بتواند بر عملکرد بینایی تأثیر بگذارد، ندارند.

بیماری ام اس یا مالتیپل اسکلروزیس یا مالتیپل اسکلروز^۱ یکی از شناخته شده ترین بیماری های خودایمنی است که در اثر حمله سامانه ایمنی به اعصاب بدن ایجاد می شود. در این بیماری سامانه ایمنی بدن به غلاف حفاظتی فیبرهای عصبی (میلین) حمله می کند و باعث ایجاد مشکلات ارتباط بین مغز و بقیه ی قسمت های بدن می شود. یکی از اثرات شایع این بیماری حمله به قسمت ماکولا^۲ در شبکه چشم و آسیب به سلول های گانگلیون شبکه^۳ است. ماکولا بخشی از شبکه است که بیشترین حساسیت به نور را دارد و موجب دید مستقیم و واضح می شود. با آسیب این بخش بیمار در انجام کارهایی که نیاز به بینایی دقیق دارند نظیر خواندن و رانندگی دچار مشکل می شود. هر چه میزان پیشرفت بیماری ام اس بیشتر باشد شدت آسیب وارد شده به شبکه چشم بیشتر و ضخامت لایه فیبرهای عصبی شبکه^۴ بیمار کمتر می شود. [۱]

بیماران ام اس در اکثر مواقع دچار اختلال در بینایی و حتی نابینایی می شوند. از هر ۱۰ بیمار مبتلا به ام اس ۷ نفر در مقطعی دچار نوریت بینایی می شوند. نوریت بینایی یا التهاب عصب بینایی بیماری است که منجر به از دست دادن ناگهانی بینایی می شود. این بیماری به طور معمول در سنین ۲۰ تا ۵۰ سالگی و در زنان حدود ۲ برابر بیشتر از مردان اتفاق می افتد. بنابراین تشخیص زود هنگام بیماری ام اس و درمان بیمار بسیار مهم می باشد. بویژه برای متخصصینی که مشاغل حساس دارند و این بیماری می تواند انجام وظایف شغلی آنها را تحت تأثیر قرار دهد. از جمله خلبانان و کارشناسان مانیتورینگ سامانه حمل و نقل هوایی.

توموگرافی انسجام نوری یا OCT^۵ یک روش پیشرفته تصویربرداری غیر تهاجمی از اجزای چشم به ویژه شبکه است. در این روش برای گرفتن عکس های مقطعی از شبکه چشم از امواج نوری استفاده می شود. با استفاده از تصاویر OCT، چشم پزشک می تواند هر یک از لایه های متمایز شبکه و لایه فیبرهای عصب بینایی را ببیند و ضخامت لایه فیبرهای عصبی شبکه را اندازه گیری کند. لذا استفاده از تصاویر OCT برای تشخیص زودهنگام بیماری های چشمی مانند ام اس بسیار مفید است. [۲، ۳]

1. MS: Multiple Sclerosis

2. Macula

3. RGCs: Retinal Ganglion Cells

4. RNFL: Retinal Nerve Fiber Layer

5. Optical Coherence Tomography

تشخیص بیماری ام اس از روی تصاویر OCT با استفاده از الگوریتم های یادگیری ماشین و بهبود دقت با ترکیب طبقه بندهای مختلف، مریم ابوطالبیان، نسرین دخت باطنی پور

گام سوم) استخراج ویژگی: در این مرحله عملیات پردازش تصاویر انجام می شود و با استفاده از الگوریتم های الگوهای محلی باینری (LBP)^۵ و مومنت زرنیک^۶ ویژگی های تصاویر استخراج می شود.

گام چهارم) در مرحله طبقه بندی، سه روش یادگیری ماشین آموزش داده شدند. برای هر یک پارامترهای استاندارد تنظیم شدند؛ به عنوان مثال، در جنگل تصادفی^۷ از معیار گینی برای تقسیم بندی استفاده شد و تعداد درخت ها^۸ برابر ۱۰۰ تنظیم گردید تا پوشش مناسبی از فضای ویژگی ها فراهم شود. در ماشین بردار پشتیبان^۹ از هسته گاو سی (RBF) با پارامترهای C و Y مناسب استفاده شد. روش K-نزدیکترین همسایه^{۱۰} نیز با مقدار $k=5$ و معیار فاصله اقلیدسی اعمال گردید. علاوه بر طبقه بندهای منفرد روش های ترکیبی نیز مورد استفاده قرار گرفت؛ در این شیوه، پیش بینی های RF، SVM، KNN و با روش رأی اکثریت ترکیب شدند تا تصمیم نهایی گرفته شود. کلیه مدل ها با اعتبار سنجی متقاطع مبتنی بر تفکیک داده های بیماران انجام شد تا از همپوشانی نمونه ها در آموزش و ارزیابی جلوگیری گردد. باید شامل این بخش های اصلی باشد: چکیده، کلمات کلیدی، مقدمه، مطالب اصلی، نتیجه و مراجع. سایر بخش ها مثل سپاسگزاری، ضمایم و زیرنویس ها اختیاری است. این بخش ها باید در آخر مقاله و قبل از مراجع قرار گیرند.

۳- پیاده سازی و تحلیل نتایج حاصل

به منظور پیاده سازی روش تشخیص بیماری ابتدا باید ویژگی های تصاویر OCT برای افراد سالم و بیمار مجموعه داده ها استخراج شوند. ابتدا برای هر تصویر چندین مرحله پیش پردازش انجام می شود:

۱. خواندن تصویر: تصویر از فایل خوانده می شود.

۲. تبدیل به سطح خاکستری: تصویر به سطح خاکستری تبدیل می شود تا فرآیند پیش پردازش ساده تر شود.

۳. تعادل سازی هسته ای: برای بهبود کیفیت تصویر، تعادل سازی هسته ای اعمال می شود.

داده ها از چشم راست ۳۵ نفر با استفاده از یک سامانه OCT طیفی به دست آمد. از ۳۵ نفر، ۲۱ نفر مبتلا به ام اس تشخیص داده شدند و ۱۴ نفر دیگر افراد سالم بودند. تمام تصاویر با غربالگری شدند و مشخص شد که ادم ماکولا میکروکیستیک (یک آسیب شناسی که گاهی در افراد مبتلا به ام اس یافت می شود) وجود ندارد. محدوده سنی ۲۰ تا ۵۶ سال بود. به صورت دستی خطوط هشت لایه رتینا در تصاویر شناسایی و برای اعتبارسنجی روش های بخش بندی خودکار استفاده شد. در جدول (۱) خلاصه ای از داده ها نمایش داده شده است.

جدول (۱): ویژگی داده ها

مجموعه داده	تعداد (زن/مرد)	میانگین سن (انحراف معیار)
کل مجموعه	۳۵ (۶/۲۹)	۳۹/۴۹ (۱۰/۹۴)
مجموعه اعضای سالم	۱۴ (۲/۱۲)	۳۵/۷۷ (۱۳/۰۳)
مجموعه بیماران ام اس	۲۱ (۴/۱۷)	۴۱/۹۷ (۸/۷۷)

این پروژه در ۴ مرحله کلی انجام می شود:

گام اول) جمع آوری داده: در این مرحله، از دیتاهای موجود در پایگاه های داده وبسایت بیمارستان جانز هاپکینز استفاده می شود. مجموعه داده ها شامل ۳۵ تصویر است که با استفاده از سامانه OCT اسپکتالیز^۱ انجام شده است. از مجموع این ۳۵ تصویر، ۱۴ تصویر مربوط به افراد سالم^۲ و ۲۱ تصویر مربوط به بیماران مبتلا به ام اس^۳ است. در این تصاویر خطوط هشت لایه رتینا به صورت دستی شناسایی شده است. این مجموعه داده ها شامل فرمت های خام و پردازش شده است.

گام دوم) پیش پردازش: استفاده از فیلتر میانه^۴ برای یکدست سازی تصویر و حذف نویزهای ضربه ای (فرکانس بالا) اهمیت دارد. جایگزین کردن میانه در هر پنجره عکس باعث می شود تا مقادیری که از میانه دورترند حذف شوند و عکس به چیزی که بیشتر در آن تکرار شده شبیه می شود. می توان گفت که فیلتر میانه به بلوری شدن عکس کمک می کند و جزئیات را از بین می برد.

5. LBP: Local Binary Patterns
6. Zernike Moments
7. N estimator
8. RF: Random Forest
9. SVM: Support Vector Machine
10. KNN: K-Nearest Neighbors

1. Spectralis
2. Healthy control
3. MS
4. Median filter

۴. فیلتر میانگین حاشیه‌ای: برای کاهش نویز و حفظ لبه‌های تصویر، فیلتر میانگین حاشیه‌ای با اندازه 3×3 اعمال می‌شود.

۵. استخراج ویژگی‌ها با استفاده از روش‌های الگوهای محلی باینری (LBP) و مومنت زرنیک

KNN classifier Confusion Matrix

Output Class \ Target Class	0	1	
0	1 14.3%	1 14.3%	50.0% 50.0%
1	2 28.6%	3 42.9%	60.0% 40.0%
	33.3% 66.7%	75.0% 25.0%	57.1% 42.9%

شکل (۱): ماتریس درهم ریختگی برای طبقه بند KNN

SVM classifier Confusion Matrix

Output Class \ Target Class	0	1	
0	0 0.0%	0 0.0%	NaN% NaN%
1	2 28.6%	5 71.4%	71.4% 28.6%
	0.0% 100%	100% 0.0%	71.4% 28.6%

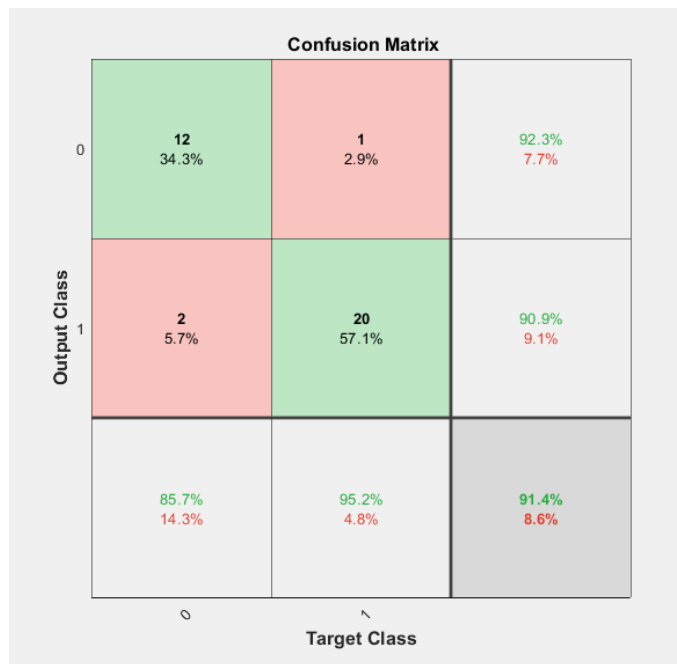
شکل (۲): ماتریس درهم ریختگی برای طبقه بند SVM

سپس الگوهای مختلف یادگیری ماشین پیاده سازی می‌شوند. برخی تصاویر مجموعه داده ها به منظور آموزش مدل یادگیری ماشین و برخی دیگر برای ارزیابی استفاده می‌شوند. نتایج حاصل از طبقه بندهای مختلف بصورت ماتریس درهم ریختگی بیان می‌شود. در این ماتریس، خروجی روش یا صفر است (کلاس صفر یعنی افراد سالم) یا یک است (کلاس یک یعنی افراد بیمار). در ماتریس درهم ریختگی وقتی یک فرد بیمار به درستی بیمار تشخیص داده شود و یک فرد سالم به درستی سالم تشخیص داده شود، نتیجه با رنگ سبز و در زمینه سبز نوشته شده است. وقتی نتیجه تشخیص اشتباه است یعنی فرد سالم به اشتباه بیمار تشخیص داده شود و یا فرد بیمار به اشتباه سالم تشخیص داده شود، با رنگ قرمز و در زمینه قرمز نوشته شده است. شکل‌های ۱ و ۲ و ۳ به ترتیب ماتریس درهم ریختگی برای طبقه بندهای KNN، SVM و جنگل تصادفی (ترکیب چند درخت تصمیم‌گیری^۱) را نشان می‌دهند.

در شکل ۱ مشاهده می‌شود که طبقه بند KNN یک فرد سالم را به درستی سالم تشخیص داده است و ۳ فرد بیمار را به درستی بیمار تشخیص داده است. درحالی‌که ۲ فرد سالم به اشتباه بیمار تشخیص داده شده اند و یک فرد بیمار به اشتباه سالم تشخیص داده شده است. احتمال اینکه فرد سالم درست تشخیص داده شود $\frac{3}{33} \%$ است و احتمال اینکه فرد بیمار درست تشخیص داده شود $\frac{5}{71} \%$ است. افرادی که سالم تشخیص داده شده اند به احتمال $\frac{50}{57} \%$ این تشخیص درست است و افرادی که بیمار تشخیص داده شده اند به احتمال $\frac{40}{42} \%$ تشخیص درست است و واقعا بیمار هستند. در مجموع ۴ تشخیص از ۷ تشخیص درست بوده است و دقت کلی این طبقه بند $\frac{57}{71} \%$ است.

1. DT: Decision Tree

تشخیص بیماری ام‌اس از روی تصاویر OCT با استفاده از الگوریتم‌های یادگیری ماشین و بهبود دقت با ترکیب طبقه‌بندی مختلف، مریم ابوطالبیان، نسرین دخت باطنی پور




شکل (۴): ماتریس در هم ریختگی حاصل از ترکیب طبقه‌بندی

در نهایت با ترکیب طبقه‌بندی به دقت پیش‌بینی صحیح ۹۱/۴٪ رسیدیم. این دقت‌ها با نتایج مطالعات مشابه‌ای که به تازگی انجام شده‌اند مطابقت دارد؛ برای نمونه، کافاکلی اوغلو و همکاران (۲۰۲۲) با روش RF و حذف ویژگی به دقت تشخیص حدود ۷۵٪ تا ۸۰٪ دست یافتند و خدابنده و همکاران (۲۰۲۳) با SVM دقت حدود ۸۸٪ را گزارش کرده‌اند. [۱۶، ۱۵]

۴- نتیجه

در این مطالعه که بر روی مجموعه داده‌های پایگاه‌های داده وب‌سایت بیمارستان جانز هاپکینز انجام شد، مطالعات مقطعی و طولانی‌مدت بر روی داده‌های بیماران مبتلا به ام‌اس (شامل زن و مرد) و افراد سالم (شامل زن و مرد) انجام شده است. در مطالعه طولانی‌مدت، بیماران مبتلا به ام‌اس در چندین ویزیت مختلف تا پیگیری ۱۰ ساله مورد بررسی قرار گرفته‌اند و مجموعه‌ای از تصاویر توموگرافی انسجام نوری (OCT) از شبکه‌ی چشم راست ۳۵ نفر بررسی شده است. تصاویر به صورت دستی خطوط هشت لایه رتینا را شناسایی کرده‌اند و برای اعتبارسنجی از روش‌های بخش‌بندی خودکار استفاده شده است. پس از استخراج ویژگی‌ها از داده‌ها، طبقه‌بندی انجام شده و دقت طبقه‌بندی مختلف برای تشخیص بیماری ام‌اس استخراج گردید. ابتدا دقت طبقه‌بندی RF، KNN و SVM به صورت



شکل (۳): ماتریس درهم ریختگی برای طبقه‌بندی DT

ماتریس درهم ریختگی برای طبقه‌بندی SVM و جنگل تصادفی را می‌توان به طور مشابه تحلیل نمود. نتایج نشان می‌دهد دقت این طبقه‌بندی به ترتیب ۷۱/۴٪ و ۸۵/۷٪ بوده است.

پس از ارزیابی جداگانه هر یک از طبقه‌بندی‌ها، در مرحله نهایی با استفاده از طراحی انسبمل (Bagging و Boosting)، نتایج حاصل از ترکیب این سه طبقه‌بندی مورد بررسی قرار گرفت. شکل ۴ ماتریس درهم ریختگی حاصل را نشان می‌دهد. نتایج پیش‌بینی‌ها به شرح زیر است:

۱. درستی مثبت (TP): پیش‌بینی کلاس ۱ زمانی که واقعاً کلاس ۱ بوده است ۵۷/۱٪ است.
۲. نادرستی مثبت (FP): پیش‌بینی کلاس ۱ زمانی که واقعاً کلاس ۰ بوده است ۵/۷٪ است.
۳. نادرستی منفی (FN): پیش‌بینی کلاس ۰ زمانی که واقعاً کلاس ۱ بوده است ۲/۹٪ است.
۴. درستی منفی (TN): پیش‌بینی کلاس ۰ زمانی که واقعاً کلاس ۰ بوده است ۳۴/۳٪ است.

- [11] D. Le, T. Son, and X. Yao, "Machine learning in optical coherence tomography angiography," *Experimental Biology and Medicine*, vol. 246, no. 20, pp. 2170-2183, 2021.
- [12] M. Ortiz *et al.*, "Diagnosis of multiple sclerosis using optical coherence tomography supported by artificial intelligence," *Multiple Sclerosis and Related Disorders*, vol. 74, p. 104725, 2023.
- [13] J. Saeidian *et al.*, "Automated assessment of the smoothness of retinal layers in optical coherence tomography images using a machine learning algorithm," *BMC medical imaging*, vol. 23, no. 1, p. 21, 2023.
- [14] A. Montolio, J. CEGONino, E. Garcia-Martin, and A. Perez Del Palomar, "Comparison of machine learning methods using spectralis OCT for diagnosis and disability progression prognosis in multiple sclerosis," *Annals of biomedical engineering*, vol. 50, no. 5, pp. 507-528, 2022.
- [15] B. Ciftci Kavaklioglu *et al.*, "Machine learning classification of multiple sclerosis in children using optical coherence tomography," *Multiple Sclerosis Journal*, vol. 28, no. 14, pp. 2253-2262, 2022.
- [16] Z. Khodabandeh *et al.*, "Discrimination of multiple sclerosis using OCT images from two different centers," *Multiple Sclerosis and Related Disorders*, vol. 77, p. 104846, 2023.

جداگانه به ترتیب ۸۵٪، ۵۷٪ و ۷۱٪ بدست آمد که نشان داد روش RF نسبت به SVM و KNN دقت بیشتری دارد. سپس برای افزایش دقت تشخیص، از ترکیب طبقه‌بندها استفاده شد که نتیجه آن رسیدن به دقت نهایی ۹۱٪ بود.

مراجع

- [1] G. Xu, R. N. Weinreb, and C. K. Leung, "Retinal nerve fiber layer progression in glaucoma: a comparison between retinal nerve fiber layer thickness and retardance," *Ophthalmology*, vol. 120, no. 12, pp. 2493-2500, 2013.
- [2] S. Aumann, S. Donner, J. Fischer, and F. Müller, "Optical coherence tomography (OCT): principle and technical realization," *High resolution imaging in microscopy and ophthalmology: new frontiers in biomedical optics*, pp. 59-85, 2019.
- [3] S. B. Rutkove, "Clinical measures of disease progression in amyotrophic lateral sclerosis," *Neurotherapeutics*, vol. 12, no. 2, pp. 384-393, 2015.
- [4] I. Ghorbel, F. Rossant, I. Bloch, S. Tick, and M. Paques, "Automated segmentation of macular layers in OCT images and quantitative evaluation of performances," *Pattern Recognition*, vol. 44, no. 8, pp. 1590-1603, 2011.
- [5] Q. Li *et al.*, "DeepRetina: layer segmentation of retina in OCT images using deep learning," *Translational vision science & technology*, vol. 9, no. 2, pp. 61-61, 2020.
- [6] C. K. S. Leung *et al.*, "Diagnostic assessment of glaucoma and non-glaucomatous optic neuropathies via optical texture analysis of the retinal nerve fibre layer," *Nature Biomedical Engineering*, vol. 6, no. 5, pp. 593-604, 2022.
- [7] E. López-Varela, N. Barreira, N. O. Pascual, E. G. Ben, S. R. Cid, and M. G. Penedo, "Fully automatic segmentation of the choroid in non-EDI OCT images of patients with multiple sclerosis," *Procedia Computer Science*, vol. 207, pp. 726-735, 2022.
- [8] M. Siger, M. Owidzka, M. Świderek-Matysiak, W. Omulecki, and M. Stasiółek, "Optical coherence tomography in the differential diagnosis of patients with multiple sclerosis and patients with MRI nonspecific white matter lesions," *Sensors*, vol. 21, no. 21, p. 7127, 2021.
- [9] F. J. Dongil-Moreno *et al.*, "Diagnosis of multiple sclerosis using optical coherence tomography supported by explainable artificial intelligence," *Eye*, vol. 38, no. 8, pp. 1502-1508, 2024.
- [10] K. Hartmann, B. Neyazi, C. A. Dumitru, A. Haghikia, I. E. Sandalcioglu, and K.-P. Stein, "Extravascular optical coherence tomography of cerebral vessel walls in vivo," *Plos one*, vol. 18, no. 5, p. e0276307, 2023.