

Dimension Reduction in fMRI Images based on Metaheuristic Algorithm to Diagnose Autism

Farzaneh Sadeghian, Hadiseh Hasani*, Marzieh Jafari

Department of Geodesy and Surveying Engineering, Tafresh University, Tafresh, Iran

Article Info:

Received: 26 Jan 2021

Revised: 1 June 2021

Accepted: 3 June 2021

ABSTRACT

Introduction: Autism Spectrum Disorder (ASD) is a mental disorder and affects a person's linguistic skills and social interactions. With the production of Functional Magnetic Resonance Imaging (fMRI) and the development of their processing tools, the use of these images in identifying and evaluating the brain function of autistic people received a lot of attention. However, in this approach using the functional connectivity matrices leads to the creation of feature space with very high dimensions. Some of these features are dependent, unnecessary and additional, which reduces the quality of detection and increases the number of calculations. Therefore, regarding the large dimensions of the search space, the Particle Swarm Optimization (PSO) algorithm has been used as one of the powerful meta-heuristic search tools in selecting the optimal features. **Materials and Methods:** To evaluate the capability of the proposed method, the principal component analysis (PCA) algorithm is used as a standard dimension reduction method. In this study, the Support Vector Machines (SVM) classifier was used to detect autistic and healthy persons on the ABIDE database data. Feature space has been generated based on a functional connectivity matrix which has 6670 dimensions.

Results: SVM accuracy in high-dimensional specialty space is 56%. The proposed method based on PSO eliminates 3442 redundant features and increases classification accuracy up to 62.19 % that performs better than PCA. The findings show that this meta-heuristic algorithm by removing almost half of the features results in a 6% increase in classification precision.

Conclusion: The results indicate the ability of SVM in comparison with the Random Forest and K-Nearest Neighbor (KNN). PSO algorithm was used for dimension reduction of the input data space.

Keywords:

1. Magnetic Resonance Imaging
2. Support Vector Machine
3. Autistic Disorder

*Corresponding Author: Hadiseh Hasani

Email: h.hasani@tafreshu.ac.ir



بکارگیری کاهش ابعاد در تصاویر fMRI بر اساس الگوریتم فراباتکاری جهت تشخیص اوتیسم

فرزانه صادقیان، حدیثه حسنی*، مرضیه جعفری

گروه ژئودزی و مهندسی نقشه برداری، دانشگاه تفرش، تفرش، ایران

اطلاعات مقاله:

پذیرش: ۱۳ خرداد ۱۴۰۰

اصلاحیه: ۱۱ خرداد ۱۴۰۰

دربافت: ۷ بهمن ۱۳۹۹

چکیده

مقدمه: اختلال طیف اوتیسم (ASD) یک اختلال روانی است و مهارت‌های کلامی و تعاملات اجتماعی فرد را تحت تاثیر قرار می‌دهد. با تولید تصاویر تشحیضی مغناطیسی کارکرده (fMRI) و پیشرفت ابزارهای پردازشی آن‌ها، استفاده از این تصاویر در شناسایی و بررسی عملکرد مغز افراد اوتیستیک بسیار مورد توجه قرار گرفت. البته، در این رویکرد فضای ویژگی بر مبنای ماتریس ارتباط عملکردی دارای ابعاد بسیار است. برخی از این ویژگی‌ها وابسته، غیر ضروری و اضافی هستند که کیفیت تشخیص را کاهش داده و حجم محاسبات را افزایش می‌دهد. از این رو با توجه به ابعاد بالای فضای جستجو، الگوریتم بهینه‌سازی توده ذرات (PSO) به عنوان یکی از ابزارهای قدرمند جستجوی فراباتکاری در انتخاب ویژگی‌های بهینه بکار گرفته شده است.

روش‌ها: به منظور ارزیابی قابلیت روش پیشنهادی، از الگوریتم آنالیز مولفه‌های اصلی (PCA) به عنوان یک روش بعد استاندارد استفاده می‌شود. در پژوهش حاضر، از طبقه‌بندی کننده ماشین‌های بردار پشتیبان (SVM) در تشخیص افراد اوتیستیک و سالم بر روی داده‌های پایگاه ABIDE استفاده شد. ضرایب ماتریس از تباطع عملکردی منجر به تولید فضای ویژگی با ۶۶٪ بعد می‌شود. **یافته‌ها:** دقت طبقه‌بندی کننده SVM در این فضای ویژگی ۵۶ درصد است. بکارگیری الگوریتم بهینه‌سازی توده ذرات با حذف ۳۴٪ ویژگی، دقت طبقه‌بندی را تا ۶۲٪ افزایش داد که در مقایسه با الگوریتم آنالیز مولفه‌های اصلی عملکرد بهتری دارد. نتایج کاهش ابعاد فضای ویژگی نشان می‌دهد که این الگوریتم فراباتکاری با حذف تقریباً نیمی از ویژگی‌ها منجر به افزایش ۶ درصد صحت طبقه‌بندی می‌شود.

نتیجه‌گیری: نتایج حاکی از توانایی الگوریتم ماشین‌های بردار پشتیبان در مقایسه با جنگل‌های تصادفی و نزدیک‌ترین K همسایگی می‌باشد. الگوریتم PSO به منظور کاهش بعد فضای داده ورودی استفاده شد.

واژه‌های کلیدی:

- ۱- تصاویر تشحیضی مغناطیسی
- ۲- ماشین بردار پشتیبان
- ۳- اختلال اوتیسم

*نویسنده مسئول: حدیثه حسنی

پست الکترونیک: h.hasani@tafreshu.ac.ir

مقدمه

سال ۲۰۱۵ پرداخته شد و به عنوان یک روش تشخیصی شناخته شده است، طبقه‌بندی با روش‌های مختلف یادگیری ماشین از جمله ماشین‌های بردار پشتیبان، جنگل‌های تصادفی^۱ و نزدیکترین همسایگی^۲ می‌باشد. داده‌های آموزشی شامل ۵۹ مرد مبتلا به اوتیسم و ۵۹ مرد سالم است. در این پژوهش ویژگی‌های طبقه‌بندی کنندگان با بکاربردن سه مجموعه از نواحی مغزی استخراج شده است و حداکثر صحت ۶۷/۷۶ درصد بدست آمد^(۷). شناخت ساختار و عملکرد شبکه‌ای مغز، در اولین گام مستلزم فهم ارتباط عملکردی نواحی مختلف با یکدیگر است. آنالیز داده‌ها بر اساس سری زمانی و بررسی ارتباط عملکردی شامل الگوهای فعالیت در بین نواحی مختلف است که این امر با تعیین همبستگی بین سیگنال‌های زمانی واکسل‌های^۳ تصاویر مغز صورت می‌گیرد^(۸). ایداکا در سال ۲۰۱۵ در پژوهشی به ارزیابی ماتریس عملکردی استخراج شده از سری‌های زمانی تصاویر fMRI در حالت استراحت اخذ شده از ۲۱۲ فرد مبتلا به اوتیسم و ۳۲۸ فرد سالم زیر بیست سال پرداخت. برای طبقه‌بندی از شبکه عصبی احتمالاتی^۴ استفاده کرد و به صحت تقریباً ۹۰ درصد رسید^(۹). در سال ۲۰۱۶ کسرایان فرد و همکاران به طبقه‌بندی داده‌های تصاویر fMRI حالت استراحت با استفاده از روش‌های طبقه‌بندی کننده یادگیری ماشین مانند ماشین‌های بردار پشتیبان، شبکه‌های عصبی و رویکردهای رگرسیون پرداختند و صحت تقریبی بین ۶۰ تا ۷۰ درصد را ارائه دادند^(۱۰). طی تحقیقاتی هاین‌فلد و همکاران^(۲۰۱۷) با هدف تفکیک افراد اوتیسم از افراد سالم توسط fMRI در حالت استراحت، با استفاده از ماتریس ارتباط‌های عملکردی به بررسی عملکرد نواحی مختلف مغز و استخراج ویژگی آن‌ها پرداختند. در نهایت پس از بررسی اطلاعات بدست آمده به ترتیب برای روش‌های طبقه‌بندی کننده ماشین‌های بردار پشتیبان میزان صحت ۶۵ درصد، جنگل‌های تصادفی^{۱۱} ۶۳ درصد و شبکه عصبی عمیق (DNN)^{۱۲} ۷۰ درصد بدست آمد^(۱۱). در سال ۲۰۱۸ فریدو و همکاران با استفاده از تصاویر fMRI در حالت استراحت به بررسی نواحی مختلف مغز توسط ماتریس ارتباط‌های عملکردی پرداختند. برای این منظور، همبستگی سری زمانی نواحی درگیر ارزیابی شده و با استفاده از طبقه‌بندی کننده جنگل تصادفی به صحت ۶۵ درصد رسیدند^(۱۲). کنگ و همکاران^(۲۰۱۹) با استفاده از تصاویر تشدید مغناطیسی کارکردی^{۱۳} سپس با استفاده از روش طبقه‌بندی کننده شبکه عصبی عمیق به صحت ۹۳/۳۹ درصد رسیده‌اند^(۱۳). اسلامی و همکاران^(۲۰۱۹) با

اختلال طیف اوتیسم که اولین بار در سال ۱۹۴۳ توسط لئوکارنر روانپژوهی کودک در آمریکا معرفی شد، مهارت‌های کلامی، دیداری، شنیداری، لمسی و تعاملات اجتماعی فرد را تحت تاثیر قرار می‌دهد^(۱). به دلیل افزایش سریع و پیش‌رونده اختلال طیف اوتیسم در سال‌های اخیر و همچنین نبود درمان قطعی برای آن، با استفاده از نقشه‌برداری مغز^۱ و به کمک ابزارها و تجهیزات پیشرفته اعم از اسکنرهای تصویربرداری و دستگاه‌های ثبت سیگنال‌های مغز و با بهره‌گیری از مدل‌های ریاضی و آماری پیشرفته، تغییرات ارتباطات عملکردی مغز بیماران اوتیستیک نسبت به افراد سالم مورد بررسی قرار می‌گیرد^(۲). تصویربرداری تشدید مغناطیسی کارکردی مشهور به fMRI از جمله تکیک‌های کارا برای مطالعه تغییرات ارتباطات عملکردی نواحی مختلف مغز (در حالت فعالیت^۲ و یا در حالت استراحت^(۳)) با بررسی تغییرات جریان و میزان اکسیژن خون^۴ است که اولین بار توسط اگاوا مطرح شد^(۳). این روش به دلیل ذات غیرتهداجمی، دسترسی آسان، حد تفکیک زمانی- مکانی نسبتاً بالا و توانایی مدل کردن عملکرد نواحی مختلف مغز بسیار مورد توجه محققان قرار گرفته است. با توجه به اینکه مغز انسان در حالت استراحت حدود ۲۰ درصد کل انرژی بدن و با تحريك مغز (در حالت فعالیت) ۲۵ درصد انرژی را مصرف می‌کند؛ بدین ترتیب مطالعه میزان عملکرد مغز در حالت استراحت به دلیل متابولیسم بیشتر انرژی وجود همبستگی بالا بین نواحی مختلف مغز بسیار مورد توجه محققان قرار گرفت^(۴). نیلسون و همکاران^(۲۰۱۳) با استفاده از تصویربرداری fMRI در حالت استراحت به شناسایی افراد اوتیستیک و سالم توسط ماتریس ارتباط‌های عملکردی و بررسی عملکرد نواحی مختلف مغز از یکدیگر و استخراج ویژگی آن‌ها پرداختند و با استفاده از آزمون آماری تی صحت پایین این نتایج را نحوه برقراری ارتباط شبکه‌های عصبی مغز با یکدیگر در زمان تصویربرداری گزارش دادند^(۵). نتایج تحقیقات دیکاستین و همکاران^(۲۰۱۳) که بر اساس تصاویر fMRI مبتنی بر سن انجام شد و عملکرد وظایف روزانه در مغز را مورد بررسی قرار داد، نشان می‌دهد که در هر دو گروه سنی کودکان و بزرگسالان مبتلا به اوتیسم قشر پیش‌پیشانی^۶، قشر گیجگاهی^۷ و قشر آهیانه‌ای^۸ درگیر می‌باشد^(۶). در یکی از پژوهش‌هایی که به ارزیابی ارتباطات عملکردی نواحی مختلف مغز در تصاویر fMRI حالت استراحت توسط پلیت و همکاران در

¹ Brain Mapping² Task³ Rest⁴ Blood Oxygenation Level Dependent (BOLD)⁵ Prefrontal Cortex⁶ Temporal Cortex⁷ Parietal Cortex⁸ Random Forests⁹ KNN: K-Nearest Neighbor¹⁰ Voxel¹¹ Probabilistic Neural Network (PNN)¹² Random Forests¹³ Deep Neural Network

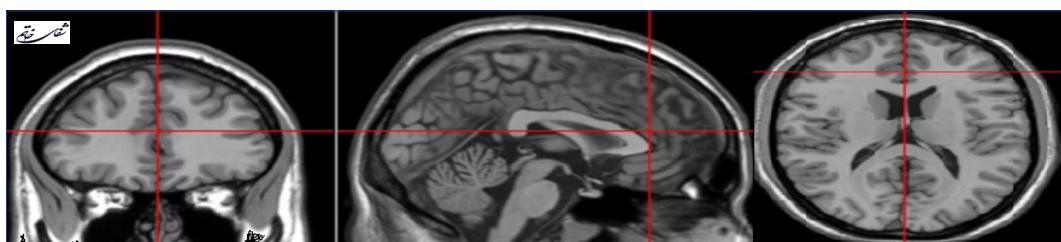
بر این، همچنین از الگوریتم ماشین‌های بردار پشتیبان را روی همان مجموعه داده اعمال کردند و نتایج قابل مقایسه‌ای بدست آوردند که نتایج بدست آمده حاکی از آن است که شبکه عصبی کانولوشن سه بعدی قادر نیست اطلاعات اضافی را بر اساس تحولات زمانی برای تفکیک دو گروه سالم و اوتیستیک را نشان دهد (۱۷). در مطالعات انجام شده، برای تشخیص سریع و دقیق وضعیت اختلال طیف اوتیسم و علائم آن از انواع روش‌های طبقه‌بندی کننده داده و مدل‌های ارزیابی صحت استفاده شده است. با توجه به تحقیقات به روز در این حوزه، همچنان توجه کمی به کاهش ابعاد فضای داده‌های ورودی شده و خلاصه این موضوع احساس می‌شود. در پژوهش حاضر، برای کاهش ابعاد فضای ویژگی داده‌های ورودی با هدف افزایش صحت و کاهش زمان برای شناسایی افراد اوتیستیک و سالم از الگوریتم بهینه‌سازی توده ذرات استفاده شده است.

مواد و روش

برای انجام پژوهش حاضر، از تصاویر fMRI پایگاه DADDIE ABIDE استفاده شده است. در مساله پیش رو، انتخاب یک زیر مجموعه بهینه که منجر به افزایش صحت طبقه‌بندی شود با توجه به ابعاد بالای فضای ویژگی، یک مساله بهینه‌سازی سخت^{۲۰} می‌باشد. از این رو پس از استخراج ماتریس ارتباط عملکردی، الگوریتم بهینه‌سازی توده ذرات برای کاهش ابعاد فضای ویژگی داده‌ها مورد استفاده قرار گرفته است.

داده‌های پژوهش

برای انجام پژوهش حاضر، از تصاویر fMRI در پایگاه DADDIE ABIDE استفاده شده است. این مجموعه شامل داده‌های جمع‌آوری شده از ۱۷ موسسه پژوهشی با نمونه ۸۲۰ بوده که از این تعداد ۵۰۵ نفر مبتلا به طیف اختلالات اوتیسم هستند که توسط متخصص تایید شده است (۱۸). همچنین این مجموعه پژوهشی شامل یک تصویر تشخیصی مغناطیسی ساختاری (sMRI)^{۲۱} با حد تفکیک مکانی بالا و تصویر تشخیصی عملکردی در حالت استراحت از هر فرد به همراه اطلاعاتی مانند سن، جنس، ضریب هوشی و غیره می‌باشد (۱۹). در تصویر (۱) نمونه‌ای از تصویر حالت استراحت fMRI نمایش داده شده است.



تصویر ۱- تصویر حالت استراحت fMRI

استفاده از شبکه عصبی پرسپترون تک لایه^{۱۴} ۱۰۳۵ داده تصاویر تشخیصی کارکردی را طبقه‌بندی کرده و به صحت ۷۰ درصد رسیدند. تکنیک طبقه‌بندی ارائه شده در این مقاله علاوه بر کیفیت بهتر، از نظر کاهش زمان اجرا نیز نسبت به روش‌های طبقه‌بندی مورد استفاده در تحقیقات هاین‌فلد حائز اهمیت است (۱۱، ۱۴). یکی از مشکلات اصلی در زمینه تجزیه و تحلیل تصاویر تشخیصی کارکردی وجود حجم بالای داده‌ها می‌باشد. هرچند آنالیز استخراج اطلاعات مربوط به ارتباطات عملکردی، اطلاعات کاملی پیرامون نحوه ارتباط نواحی مختلف مغز را فراهم می‌کند، ابعاد بالای فضای ویژگی مرحله طبقه‌بندی و آنالیز را با چالش‌هایی روبرو می‌کند. از این رو انتخاب ویژگی یکی از موضوعات مهم در تفکیک افراد اوتیستیک از افراد سالم محسوب می‌شود. از جمله اهداف انتخاب ویژگی می‌توان به کاهش ابعاد ویژگی‌های استخراج شده و کاهش حجم داده‌ها، افزایش سرعت عملیات، بالابردن صحت الگوریتم‌های یادگیری ماشین و درک بهتر نتایج اشاره کرد. در سال ۲۰۲۰ شیهاب و همکاران با هدف کاهش ابعاد ویژگی‌های استخراج شده، از روش آنالیز مولفه اصلی و طبقه‌بندی بدون نظارت سلسه مراتبی^{۱۵} استفاده کردند. سرانجام، نتایج کلی روش پیشنهادی نسبت به روش‌های طبقه‌بندی کننده ماشین‌های بردار پشتیبان و جنگل‌های تصادفی برای کودکان و بزرگسالان مبتلا با کاهش ابعاد ویژگی داده‌های ورودی، با میانگین حساسیت^{۱۶} ۸۰ درصد و تشخیص^{۱۷} ۹۰ درصد برآورد شده است (۱۵). اسلامی و همکاران (۲۰۲۰) با استفاده تصاویر fMRI برای اولین بار توسط روشی با نام Auto-ASD-Network مبتنی بر ترکیبی از روش‌های یادگیری عمیق و الگوریتم طبقه‌بندی کننده ماشین‌های بردار پشتیبان برای طبقه‌بندی افراد مبتلا به اوتیسم و سالم را به عنوان روش پیشنهادی ارائه دادند. رویکرد مهم این پژوهش افزایش صحت، تشخیص، پیش‌آگهی و راههای درمان اختلالات روانی مانند بیشفعالی (ADHD)^{۱۸} و اوتیسم می‌باشد (۱۶). در پژوهش توماس و همکاران (۲۰۲۰) برای انکاس مکانیسم تبادل اطلاعات بین نواحی مختلف مغز با استفاده از تصاویر حالت استراحت fMRI از شبکه عصبی کانولوشن سه بعدی (3D-CNN)^{۱۹} استفاده کردند. علاوه

¹⁴ ASD-DiagNet

¹⁵ HC: Hierarchical Classification

¹⁶ Sensitivity

¹⁷ Specificity

¹⁸ Attention Deficit Hyperactivity Disorder (ADHD)

¹⁹ Three-Dimensional Convolutional Neural Network

²⁰ NP-hard

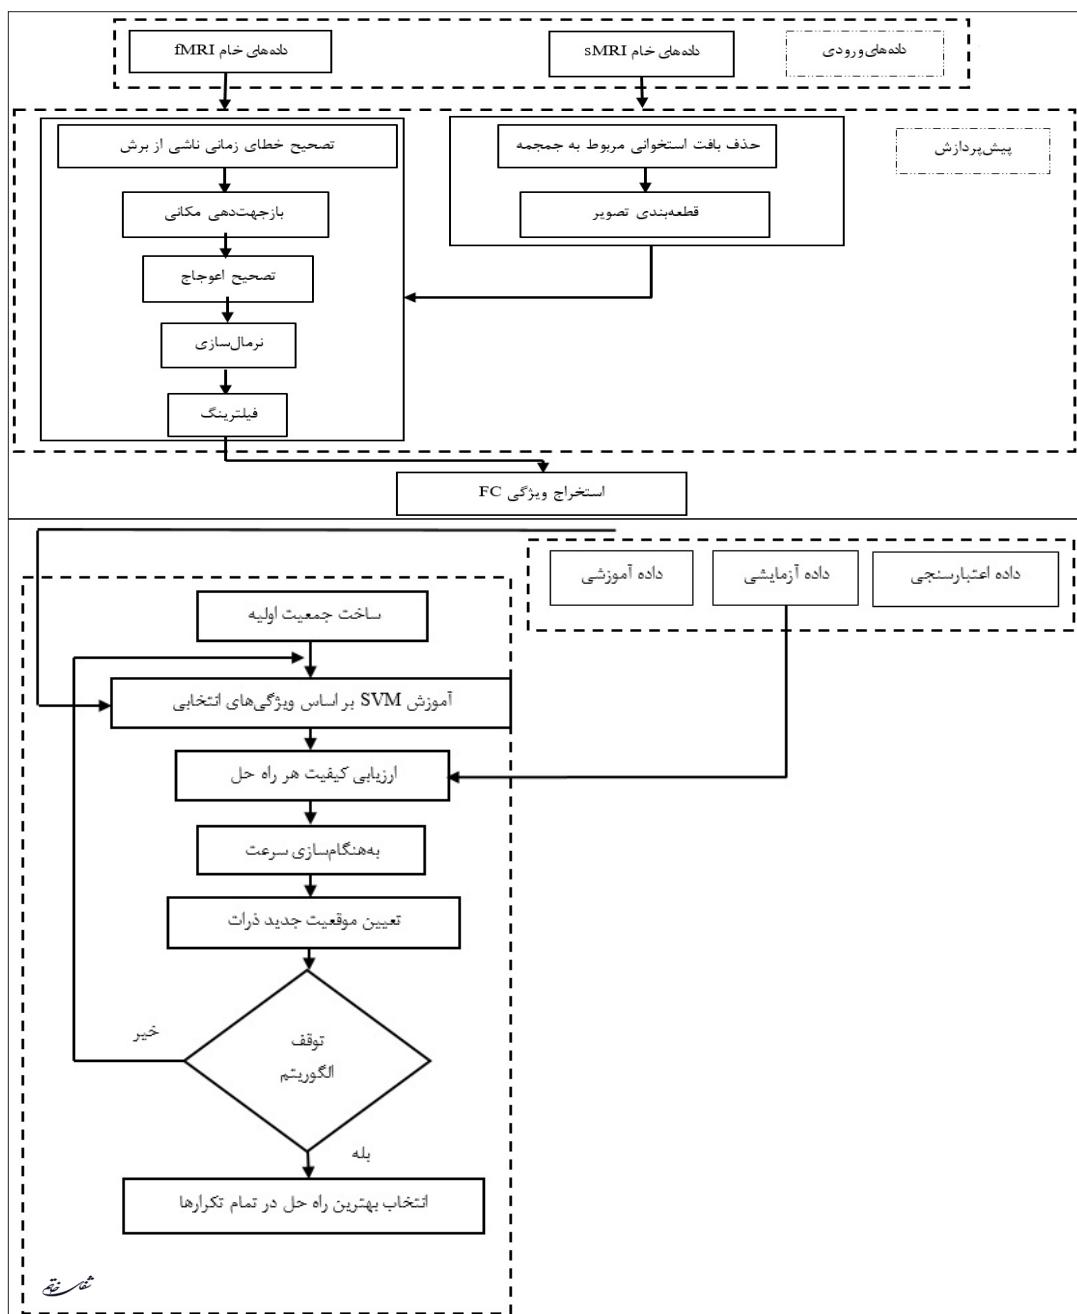
²¹ Structural Magnetic Resonance Imaging (sMRI)

پیش‌پردازش تصاویر fMRI

از آنجائی که تصاویر fMRI نسبت به تصاویر sMRI دارای قدرت تفکیک مکانی بالاتری هستند، لذا از این تصاویر جهت بهبود قدرت تفکیک مکانی در مرحله پیش‌پردازش تصاویر fMRI استفاده می‌شود. تصاویر sMRI شامل استخوان جمجمه، چربی و پوست سر می‌باشند. چنانچه این قسمت‌ها حذف شوند، صحت نگاشت تصاویر نسبت به یکدیگر افزایش می‌یابد. به منظور

روش پیشنهادی

روش پیشنهادی از سه گام اصلی تشکیل شده که مراحل آن در فلوچارت تصویر ۲ نمایش داده شده است. در گام نخست بر روی داده‌های ورودی با هدف کاهش نویز و بهبود کیفیت تصویر یک پیش‌پردازش انجام می‌شود. سپس فضای ویژگی برمنای ماتریس ارتباط عملکردی ساخته شده و در نهایت ابعاد فضای ویژگی بهینه با استفاده از الگوریتم بهینه‌سازی توده ذرات تعیین می‌شود.



تصویر ۲- فلوچارت روش پیشنهادی

برای آن ناحیه استخراج می‌شود. در واقع طول سری زمانی مستخرج مربوط به هر ناحیه، به تعداد تصاویر سه‌بعدی دریافت شده از هر فرد است؛ ارتباط عملکردی بین ۱۱۶ ناحیه مغز با استفاده از ضریب پیرسون^{۲۲} که میزان همبستگی خطی بین سری‌های زمانی نواحی مختلف را مشخص می‌کند، تعیین می‌شود. مقدار این ضریب که بین ۱ و -۱ است، قدرت ارتباط عملکردی بین نواحی مختلف مغز را تعیین می‌کند. در صورتی که وابستگی کامل بین دو ناحیه وجود داشته باشد، مقدار آن ۱، اگر هیچ وابستگی بین دو سری زمانی وجود نداشته باشد، برابر صفر و در حالتی که عملکرد دو ناحیه کاملاً معکوس باشد -۱ خواهد شد. ضریب پیرسون طبق رابطه ۱ محاسبه می‌شود.

$$r_{ij} = \frac{\sum_{t=1}^n [(x_i(t) - \bar{x}_i)(x_j(t) - \bar{x}_j)]}{\sqrt{\sum_{t=1}^n [x_i(t) - \bar{x}_i]^2} \sqrt{\sum_{t=1}^n [x_j(t) - \bar{x}_j]^2}} \quad (1)$$

در رابطه فوق، n تعداد تصاویر بدست آمده از کل مغز است. $x_i(t)$ به ترتیب، مقدار سیگنال سری زمانی در دو ناحیه i و j در زمان t است. \bar{x}_i و \bar{x}_j میانگین سیگنال سری زمانی در این دو ناحیه می‌باشد. با توجه به در نظر گرفتن ۱۱۶ ناحیه در مغز، 6670 ویژگی بر اساس ضریب پیرسون ایجاد خواهد شد.

کاهش ابعاد مبتنی بر الگوریتم بهینه‌سازی توده ذرات

هرچند آنالیز استخراج اطلاعات مربوط به ارتباطات عملکردی، اطلاعات کاملی پیرامون نحوه ارتباط نواحی مختلف مغز را فراهم می‌کند، ابعاد بالای فضای ویژگی (هزاران ویژگی) و اهمیت هر کدام از آن‌ها، مرحله طبقه‌بندی و آنالیز را با چالش‌هایی روبرو می‌کند. از این رو انتخاب ویژگی‌ها یکی از موضوعات مهم در تفکیک افراد اوتیستیک از افراد سالم محسوب می‌شود. تاکنون روش‌های مختلفی برای انتخاب ویژگی در علوم مختلف مطرح شده است که در این میان استفاده از روش‌های فرآبستکاری برای مجموعه داده‌های با حجم بالا موثرتر واقع شده است. الگوریتم‌های جستجوی فرآبستکاری از فرآیندهای زیستی و بیولوژیکی موجود در طبیعت الهام گرفته شده‌اند و اکثر آن‌ها به صورت جمعیتی عمل می‌کنند. الگوریتم بهینه‌سازی توده ذرات یکی از الگوریتم‌های فرآبستکاری کارا می‌باشد که در سال ۱۹۹۵ توسط کندی و همکاران معرفی شد. این الگوریتم یکی از روش‌های بهینه‌سازی جمعیت-مینا است که از روی رفتار اجتماعی جستجوی غذای گروه پرندگان مدل شده است (۲۶). به منظور بکارگیری الگوریتم بهینه‌سازی توده ذرات در مساله انتخاب ویژگی از کدگذاری دودویی^{۲۳} استفاده شده است. در گام نخست موقعیت و سرعت اعضای جمعیت اولیه به

آماده‌سازی تصاویر fMRI برای پردازش‌های اصلی لازم است تا پیش پردازش‌های مختلفی بر روی تصاویر اعمال شود. تصحیح خطای زمانی ناشی از برش^{۲۴}: روش متداول برای اصلاح زمان‌بندی برش‌ها به این صورت است که یکی از برش‌ها به عنوان برش مرجع انتخاب می‌گردد و پس از شیفت دادن سیگنال سایر برش‌ها به سمت برش مرجع، اختلاف زمانی با استفاده از درون‌پایی تصحیح می‌گردد (۲۰). بازجهت‌دهی مکانی^{۲۵}: حرکت سر باعث می‌شود که به هنگام تصویربرداری الزاماً یک واکسل بکسان در تمام برش‌ها در مکان اولیه خود قرار نگیرد. جهت رفع این مسئله بازجهت‌دهی مکانی با روش کمترین مربعات و بر مبنای تبدیل شش پارامتری (حرکت انتقالی و چرخشی حول سه محور x, y, z) انجام می‌گیرد (۲۱). تصحیح اعوجاج^{۲۶}: در این پژوهش با نگاشت تصاویر مغز به اطلس استاندارد MNI-152، هر یک از نواحی را به خوبی می‌توان مشخص نمود (۲۱). نرمال‌سازی^{۲۷}: در این مرحله، تمامی تصاویر سطح مقطع براساس سیستم مختصات استاندارد تراز می‌شوند. برای این منظور، تبدیلات خطی افاین^{۲۸} که شامل ۱۲ درجه آزادی (شش پارامتر شیفت و دوران، سه پارامتر تغییرات مقیاس و سه پارامتر درجه تغییرات برش) می‌باشد برای مدل کردن تغییرات ناشی از موقعیت سر بکار می‌رود (۲۱). فیلترینگ مکانی^{۲۹}: در این مرحله با استفاده از هموارسازی، میانگین تمام نقاط داده را نسبت به نقاط مجاور مورد محاسبه قرار می‌گیرد. فیلترینگ زمانی^{۳۰}: از آنجایی که سیگنال BOLD در اثر تغییرات جریان خون در مغز بوجود می‌آید، با افزایش میدان مغناطیسی نویزهای فیزیولوژیکی مانند ضربان قلب و تغییرات ناشی از تنفس با نوسانات فرکانس پایین و همچنین نویزهایی با نوسانات فرکانس بالا که وابسته به دستگاه اسکنر ایجاد می‌شوند. برای حذف این منابع غیر مرتبط از سیگنال سری زمانی واکسل‌ها، از فیلترینگ زمانی استفاده می‌شود تا مقدار سیگنال به نویز برابود یابد (۲۱).

استخراج ویژگی بر اساس ارتباط عملکردی

با ایجاد نقشه ارتباطات عملکردی از مغز، عملکرد و همبستگی سری‌های زمانی بین نواحی مختلف مغز^{۲۹} تعیین می‌شود. خروجی این روش، ماتریس ارتباط عملکردی مغز است که ضرایب همبستگی بین نواحی در آن قرار دارد (۲۲، ۲۴)، در این پژوهش از الگوی برچسب گذاری (اطلس) خودکار آناتومیکی (ALL)^{۳۰} که مغز انسان را به ۱۱۶ ناحیه تقسیم می‌کند، استفاده شده است (۲۵). به ازای هر ناحیه بر اساس میانگین گیری از سری‌های زمانی سیگنال BOLD واکسل‌های آن ناحیه در تصویر پیش پردازش شده، یک سری زمانی

²² Slice Timing Correction

²³ Spatial Realignment

²⁴ Distortion Correction

²⁵ Normalization

²⁶ Affine

²⁷ Spatial Smoothing

²⁸ Temporal Filtering

²⁹ Region of Interest(ROI)

³⁰ Automated Anatomical Labeling

³¹ Pearson Correlation Coefficient

³² Binary Coding

جستجوی سراسری^{۳۳} الگوریتم، بیشترین میزان وزن اینرسی در نظر گرفته می‌شود و برای افزایش جستجوی محلی در ادامه از مقادیر کوچکتر وزن اینرسی استفاده می‌شود. تغییرات این وزن در رابطه (۶) بیان شده است.

$$(6) w = w_{\max} - t \times ((w_{\max} - w_{\min}) / \text{Max}_{\text{iter}})$$

در این معادله، w مقدار وزن در تکرار t و Max_{iter} بیشترین میزان وزن اینرسی و w_{\min} کمترین میزان وزن اینرسی را نشان می‌دهد. به منظور حفظ اندازه گام‌های ذرات، حداقل و حداقل سرعت برای ذرات در نظر گرفته شد. پس از محاسبه سرعت طبق رابطه ۵، درصورتی که این مقدار کمتر از سرعت کمینه یا بیشتر از سرعت بیشینه باشد، به ترتیب با کمترین یا بیشترین مقدار سرعت جایگزین می‌شود. به منظور به هنگام‌سازی موقعیت جدید هر ذره در الگوریتم بهینه‌سازی توده ذرات استاندارد، با افزودن بردار سرعت به موقعیت فعلی ذره، موقعیت جدید محاسبه می‌شود. از آنجائی که در روش پیشنهادی از کدگذاری دودویی استفاده شده است، لازم است تا بردار موقعیت جدید دودویی باشد. برای این منظور، درایه‌های بردار سرعت بدست آمده را در تابع سیگموئید طبق رابطه ۷ قرار داده تا به محدوده [۰،۱] انتقال پیدا کند.

$$(7) S(V_{ij}) = \frac{1}{1 + \exp(-V_{ij})}$$

پس از محاسبه مقدار هر بعد از بردار موقعیت برای هر ذره، موقعیت هر آن بر اساس معادله (۸) بهروزسانی می‌شود.

$$(8) X_{ij} = \begin{cases} 1 & p_{ij} < S(V_{ij}) \\ 0 & \text{otherwise} \end{cases}$$

در این رابطه p_{ij} عددی تصادفی در محدوده [۰،۱] می‌باشد. به این ترتیب موقعیت جدید هر ذره محاسبه می‌شود. الگوریتم با موقعیت و سرعت جدید ذرات تکرار می‌شود تا با برقراری شرط توقف (بیشینه تکرارها یا خطای کمینه) متوقف شود. در نهایت بهترین عضو در تمامی تکرارها به عنوان نتیجه نهایی انتخاب می‌شود.

یافته‌ها

به منظور ارزیابی قابلیت روش پیشنهادی، از تصاویر پایگاه داده ABIDE fMRI مجموع ۸۲۰ تصویر سه بعدی از مغز پس از عملیات پیش‌پردازش ثبت گردیده است که از این تعداد ۳۷۵ نفر مبتلا به اختلال طیف اوتیسم و مابقی افراد سالم می‌باشند. از این بین هر گروه، ۶۰ درصد نمونه‌ها به عنوان داده آموزشی، ۲۰ درصد داده آزمایشی و ۲۰ درصد برای ارزیابی داده‌های اعتبارسنجی به صورت تصادفی انتخاب شدند. در این مطالعه، برای تمامی نمونه‌ها ۱۱۶ ناحیه در مغز هر فرد در نظر گرفته شده

صورت تصادفی ایجاد می‌شوند. متغیرهای موقعیت هر عضو از جمعیت به تعداد ابعاد فضای ویژگی می‌باشد. وجود صفر یا یک در هر درایه به ترتیب نشان دهنده عدم انتخاب یا انتخاب ویژگی منتظر می‌باشد. همچنین بردار سرعت هر ذره نیز به صورت تصادفی در محدوده مشخص شده، تعیین می‌شود. به منظور ارزیابی کیفیت هر راه حل، طبقه‌بندی نظارت شده انجام می‌شود. در این گام، طبقه‌بندی داده‌ها براساس ویژگی‌های منتخب انجام می‌شود. در این مطالعه، برای تشخیص دقیق اختلال طیف اوتیسم و تفکیک داده‌ها از الگوریتم طبقه‌بندی کننده نظارت شده ماشین‌های بردار پشتیبان استفاده شده است. الگوریتم طبقه‌بندی کننده ماشین‌های بردار پشتیبان در سال ۱۹۹۵ توسط وپنیک و همکاران توسعه داده شد (۲۷). پس از آموزش طبقه‌بندی کننده با داده‌های آموزشی، از داده‌های آزمایشی با ویژگی‌های منتخب برای ارزیابی عملکرد طبقه‌بندی کننده استفاده می‌شود. به منظور ارزیابی نتایج نهایی از معیارهای صحت، حساسیت و تشخیص استفاده می‌شود که به ترتیب بر اساس روابط (۲)، (۳) و (۴) محاسبه می‌شوند. در این مطالعه از صحت طبقه‌بندی به عنوان تابع هدف استفاده شده است.

$$(2) \quad \text{Accuracy} = (TP+TN)/(TP+TN+FP+FN)$$

$$(3) \quad \text{Sensitivity} = TP / (TP + FN)$$

$$(4) \quad \text{Specificity} = TN / (FP + TN)$$

در این رابطه TP تعداد افراد مبتلا به اوتیسم که الگوریتم طبقه‌بندی آن‌ها را به صورت صحیح بیمار تشخیص داده است. FP تعداد افراد سالمی است که به اشتباه بیمار تشخیص داده است. TN تعداد افراد سالم است که بدرستی سالم تشخیص داده شده‌اند و FN تعداد افراد بیماری است که به اشتباه سالم تشخیص داده‌اند. پس از ارزیابی کیفیت تمام اعضای جمعیت، بهترین موقعیت هر عضو تا تکرار فعلی و بهترین موقعیت در بین کل جمعیت تعیین می‌شوند.

(۵) بردار سرعت اعضای جمعیت به روزرسانی می‌شود.

$$(5) V_{ij}(t) = w \times V_{ij}(t-1) + c_1 \times r_1 \times (p_{best} - X_{ij}(t-1)) + c_2 \times r_2 \times (g_{best} - X_{ij}(t-1))$$

در این رابطه پارامترهای X_{ij} و V_{ij} به ترتیب موقعیت و سرعت ذره i ام در متغیر z ام و t تعداد تکرار الگوریتم می‌باشند. ضرایب c_1 و c_2 ثابت‌های شتاب هستند که به ترتیب نشان دهنده تمایل ذره به سوی موقعیت‌های p_{best} و g_{best} می‌باشند. پارامترهای r_1 و r_2 دو عدد تصادفی با توزیع یکنواخت در بازه [۰،۱] می‌باشند. پارامتر w وزن اینرسی است که در تکرارهای الگوریتم متغیر در نظر گرفته می‌شود. در تکرار اولیه برای افزایش

^{۳۳} Exploration

شماره چهارم

بر روی داده‌های ورودی در جدول ۱ آورده شده است. نتایج بدست آمده در جدول ۱ حاکی از برتری ماشین‌های بردار پشتیبان در مقایسه با نزدیک‌ترین K همسایگی و جنگل‌های تصادفی است. هرچند طبقه‌بندی کننده

و در نتیجه تعداد ۶۶۷۰ ضریب همبستگی محاسبه شد. پس از ساخت فضای ویژگی، عملکرد طبقه‌بندی کننده ماشین‌های بردار پشتیبان، در مقایسه با طبقه‌بندی کننده‌های نزدیک‌ترین K همسایه و جنگل‌های تصادفی ارزیابی شد. نتایج حاصل از اعمال طبقه‌بندی کننده‌ها

جدول ۱- مقایسه طبقه‌بندی کننده‌ها

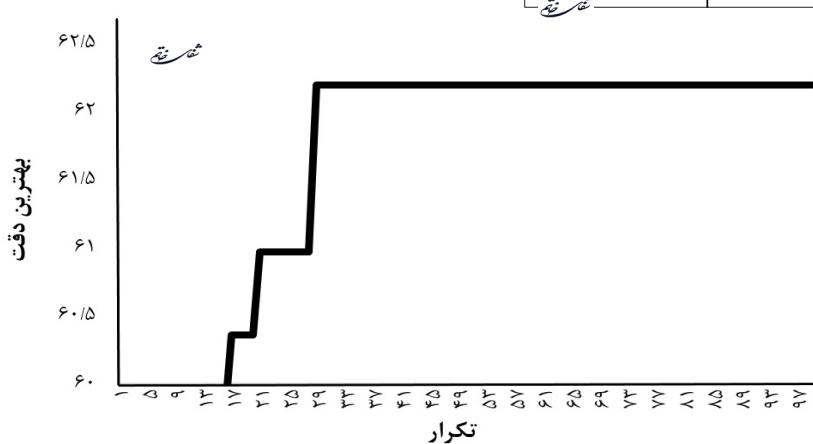
داده اعتبارسنجی				داده تست			نوع طبقه‌بندی کننده
تشخیص	حساسیت	صحت	تشخیص	حساسیت	صحت (درصد)		
۰/۶۶	۰/۵۶	۶۰/۹۷	۰/۵۲	۰/۵۹	۵۶/۰۹	ماشین‌های بردار پشتیبان	
۰/۴۰	۰/۶۷	۵۵/۴۸	۰/۲۹	۰/۷۲	۵۱/۸۲	نزدیک‌ترین همسایگی	
۰/۵۶	۰/۵۳	۵۴/۸۷	۰/۵۱	۰/۶۲	۵۷/۳۱	جنگل‌های تصادفی	

نمودار همگرایی الگوریتم بهینه‌سازی توده ذرات با استفاده از طبقه‌بندی کننده ماشین‌های بردار پشتیبان با نمایش بهترین مقدار تابع هدف در هر تکرار که نشان دهنده افزایش صحت طبقه‌بندی کننده می‌باشد، در تصویر ۳ نمایش داده شده است. نتیجه بدست آمده از الگوریتم بهینه‌سازی توده ذرات بر روی داده‌های تست و اعتبارسنجی در جدول ۳ نمایش داده شده است. بر اساس نتایج بدست آمده، الگوریتم بهینه‌سازی ذرات توانسته با حذف حدود نیمی از ویژگی‌ها صحت طبقه‌بندی را تا ۶۰ درصد بر روی داده تست و ۳۰ درصد بر روی داده اعتباری افزایش دهد. تعداد ویژگی‌های انتخاب شده توسط الگوریتم بهینه‌سازی توده ذرات برابر ۳۲۲۸ از بین ۶۶۷۰ ویژگی می‌باشد. در تصویر ۴ هیستوگرام فراوانی ۱۱۶ ناحیه در بین ویژگی‌های منتخب نمایش داده شده است. همانطور که در شکل فوق مشاهده می‌شود، تمامی نواحی تقریباً بطور یکسان در ویژگی‌های منتخب وجود دارند. به منظور بررسی نتایج الگوریتم توده ذرات، الگوریتم آنالیز مولفه‌های اصلی که یک روش استاندارد برای کاهش ابعاد داده‌ها است؛ بکار گرفته شد (۲۸). آنالیز مولفه‌های اصلی داده‌ها را از فضای ویژگی ضرایب پیرسون به فضای ویژگی دیگری نگاشت

نزدیک‌ترین K همسایگی دارای حساسیت بالاتری در مقایسه با ماشین‌های بردار پشتیبان دارد و در مقابل مقدار تشخیص و صحت در طبقه‌بندی کننده ماشین‌های بردار پشتیبان بالاترین مقدار را نسبت به سایر طبقه‌بندی کننده نشان می‌دهد. در ادامه از الگوریتم فرالبتکاری توده ذرات و طبقه‌بندی کننده ماشین‌های بردار پشتیبان جهت انتخاب زیرمجموعه‌ای از ویژگی‌های بهینه برای تشخیص اختلال طیف اوپتیمیم استفاده شد. مقادیر پارامترهای الگوریتم بهینه‌سازی توده ذرات در جدول ۲ آورده شده است.

جدول ۲- مقادیر پارامترهای الگوریتم بهینه‌سازی توده ذرات

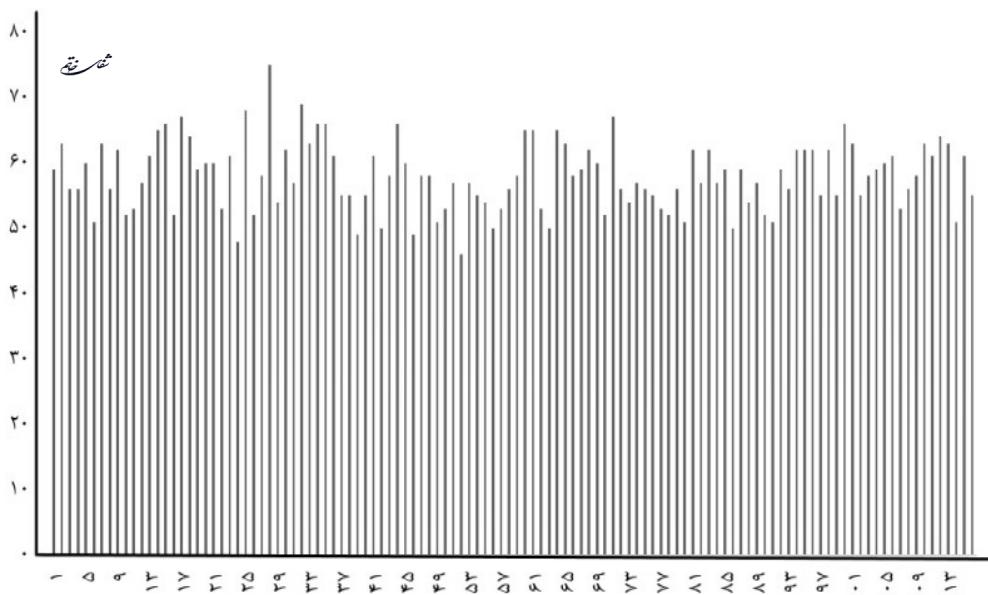
مقدار	پارامتر
۶۶۷۰	ابعاد هر ذره
۱۰	تعداد اعضای جمعیت
۱۰۰	حداکثر تکرار
(-۲، ۲)	محدوده مجاز سرعت
(۰/۰، ۴/۹)	محدوده تغییرات W
۲	C1
۲	C2



تصویر ۳- نمودار همگرایی الگوریتم بهینه‌سازی توده ذرات با استفاده از طبقه‌بندی کننده ماشین‌های بردار پشتیبان

جدول ۳- مقایسه طبقه‌بندی کننده‌ها

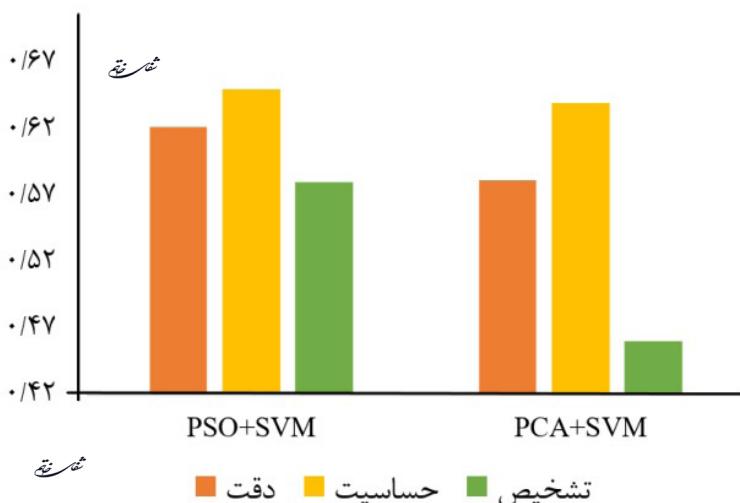
داده اعتبارسنجی			داده تست			تعداد ویژگی‌ها	نوع طبقه‌بندی کننده
تشخیص	حساسیت	صحت	تشخیص	حساسیت	صحت (درصد)		
۰/۶۶	۰/۵۶	۶۰/۹۷	۰/۵۲	۰/۵۹	۵۶/۰	۶۶۷۰	ماشین‌های بردار پشتیبان
۰/۷۱	۰/۶۷	۶۳/۴۱	۰/۵۸	۰/۶۵	۶۲/۱۹	۳۲۲۸	نزدیکترین همسایگی



تصویر ۴- هیستوگرام فراوانی ۱۱۶ ناحیه در ویژگی‌های منتخب

آمده از الگوریتم بهینه‌سازی توده ذرات مقایسه شد. نتایج بدست آمده در تصویر ۵ نشان داده شده است. با توجه به نتایج بدست آمده در تصویر ۵، مقادیر صحت، حساسیت و تشخیص با استفاده از الگوریتم بهینه‌سازی توده ذرات نسبت به روش کلاسیک آنالیز مولفه‌های اصلی بالاتر بوده که بیانگر برتری عملکرد روش پیشنهادی

می‌کند و در آن فضای با توجه به مقادیر ویژه متناظر با هر مولفه اصلی، العاد فضای را کاهش می‌دهد. در این مطالعه، ۲۰ مولفه اصلی نخست که شامل بیش از ۹۵ درصد از محتوای اطلاعات بودند انتخاب و با استفاده از ماشین‌های بردار پشتیبان طبقه‌بندی شد. در ادامه صحت نتایج طبقه‌بندی بر روی این داده با نتایج بدست



تصویر ۵- نمودار مقایسه الگوریتم بهینه‌سازی توده ذرات و آنالیز مولفه‌های اصلی

ماتریس ارتباط عملکردی توائیت صحت طبقه‌بندی کننده را شش درصد ارتقاء دهد. همچنین نتایج بیانگر توائیی طبقه‌بندی کننده ماشین‌های بردار پشتیبان در مقایسه با دو طبقه‌بندی کننده رایج نزدیک‌ترین همسایگی و جنگل‌های تصادفی است. به منظور ارزیابی روش پیشنهادی از روش آنالیز مولفه‌های اصلی به عنوان یک روش استاندارد در حوزه کاهش ابعاد فضای استفاده شد. نتایج روش پیشنهادی دارای کیفیت بالاتر به لحاظ صحت، تشخیص و حساسیت می‌باشند که حاکی از قابلیت بالای این روش است. همانطور که در پژوهش حاضر ذکر شد داده‌های پژوهشی دارای حجمی بالا می‌باشند. با توجه به گستردگی بودن الگوریتم‌های فرابابتکاری و کارایی آن‌ها در کاهش حجم ویژگی‌های استخراج شده، پیشنهاد می‌شود از سایر الگوریتم‌های فرابابتکاری در این حوزه استفاده و ویژگی‌های بهینه استخراج شده از آن‌ها با یکدیگر مقایسه شوند.

در مساله کاهش ابعاد ویژگی مستخرج می‌باشد.

بحث و نتیجه‌گیری

در این مطالعه روشی نوین با هدف بهینه‌سازی سیستم تشخیص بیماری اوتیسم از تصاویر fMRI ارائه شد. با توجه به پیشرفت تکنولوژی اخذ داده‌های پژوهشی، الگوریتم‌های پردازشی آن نیز در حال توسعه می‌باشند. استفاده از الگوریتم‌های یادگیری ماشین در سال‌های اخیر با موفقیت در این زمینه استفاده شده‌اند. هرچند به دلیل رشد سریع داده‌ها همچنان چالش‌هایی در زمینه پردازش وجود دارد. از این رو در این پژوهش رویکرد کاهش بعد برمنای الگوریتم‌های فرابابتکاری بهینه‌سازی توده ذرات در طبقه‌بندی افراد اوتیستیک و سالم برمنای تصاویر fMRI ارائه شد. نتایج بدست آمده نشان داد، الگوریتم بهینه‌سازی توده ذرات با حذف بیش از نیمی از ویژگی‌های استخراج شده از

منابع

1. Ghaffari M.A, Mousavinejad. E, Riahi. F, Mousavinejad. M, Afsharmanesh M.R. Increased Serum Levels of Tumor Necrosis Factor-Alpha, Resistin, And Visfatin in the Children with Autism Spectrum Disorders: A Case-Control Study. Hindawi Publishing Corporation; Article ID 9060751 2016.; pp: 7.
2. Savoy R.L. History and Future Directions of Human Brain Mapping and Functional Neuroimaging. Elsevier Science B.V 2001; pp: 9-42.
3. Ogawa. S. Magnetic Resonance Imaging of Blood Vessels at High Fields: in Vivo and in Vitro Measurements and Image Simulation. Magnetic Resonance Imaging 1990; vol.16, No.1. pp: 9-18.
4. Fox M.D and Raichle M.E. Spontaneous Fluctuations in Brain Activity Observed with Functional Magnetic Resonance Imaging. Nature 2007; vol. 8, pp: 700-711.
5. Nielsen J.A, Zielinski B.A, Fletcher P.T, Alexander A.L, Lange N, Bigler E.D, et. Multisite Functional Connectivity MRI Classification of Autism: ABIDE Results. Brain a Journal of Neurology 2013; pp: 134: 3742-3754.
6. Dickstein D.P, Pescosolido M.F, Reidy B.L, Galvan. T, Kim K.L, Seymour K.E, et. Developmental Meta-Analysis of the Functional Neural Correlates of Autism Spectrum Disorders. Journal of the American Academy of Child and Adolescent Psychiatry 2013; vol.52, pp: 279-289.
7. Plitt. M, Barnes K.A, Martin. A. Functional
8. Friston K.J. Functional and Effective Connectivity in Neuroimaging: A Synthesis. Hum. Brain Mapp 1994; vol.2, pp: 56-78.
9. Iidaka. T. Resting State Functional Magnetic Resonance Imaging and Neural Network Classified Autism and Control. Cortex 2015; vol.63, pp: 55-67.
10. Kassraian Fard. P, Matthys. C, Balsters J.H, Maathuis M.H, Wenderoth. N. Promises, Pitfalls, and Basic Guidelines for Applying Machine Learning Classifiers to Psychiatric Imaging Data, with Autism as an Example. Front. Psychiatry 2016; doi: 10.3389/fpsyg.2016.00177.
11. Heinsfeld A.S, Franco A.R, Craddock R.C, Buchweitz. A, Meneguzzi. F. Identification of Autism Spectrum Disorder Using Deep Learning and the ABIDE Dataset. NeuroImage: Clinical 17 2017; pp: 16-23.
12. Fredo A.R.J, Jahedi. A, Reiter. M, Müller R.A. Diagnostic Classification of Autism Using Resting-State fMRI Data and Conditional Random Forest. IEEE; 978-1-5386-3646-6/18/\$31.00, 2018.
13. Kong. Y, Gao. J, Xu. Y, Pan. Y, Wang. J, Liu. J. Classification of Autism Spectrum Disorder by Combining Brain Connectivity and Deep Neural Network Classifier. Neurocomputing 2018; pp: 63-68.

14. Eslami. T, Mirjalili. V, Fong. A, Laird. A, Saeed. F. ASD-DiagNet: A Hybrid Learning Approach for Detection of Autism Spectrum Disorder Using fMRI Data. arXiv:1904.07577v1, 2019.
15. Shihab A.I, Dawood F.A, Kashmar. AH. Data Analysis and Classification of Autism Spectrum Disorder Using Principal Component Analysis. Hindawi 2020; Article ID 3407907, pp: 8.
16. Eslami. T, S. Raiker. J, Saeed. F. Explainable and Scalable Machine-Learnig Algorithms for Detection of Autism Spectrum Disorder Using fMRI Data. Neurons and Cognition 2020; arXiv:2003.01541.
17. Thomas R.M, Gallo. S, Cerliani. L, Zhutovsky. P, El-Gazzar. A, Wingen GV. Classifying Autism Spectrum Disorder Using the Temporal Statistics of Resting-State Functional MRI Data with 3D Convolutional Neural Networks. Front. Psychiatry 2020; doi: 10.3389/fpsyg. 2020. 00440.
18. ABIDE, <http://fcon1000.projects.nitrc.org/indi/abide>.
19. Di Martino. A, Yan C.G, Li. Q, Denio. E, Castellanos F.X, Alaerts. K, et al. The Autism Brain Imaging Data Exchange: Towards a Large-Scale Evaluation of the Intrinsic Brain Architecture in Autism. Molecular psychiatry 2013; vol.19, no.6, pp: 1-9.
20. Poldrack R.A, Mumford J.A, Nichols T.E. Handbook of Functional MRI Data Analysis. Columbia University Libraries 2011; vol.10.1017/CBO9780511895029(1), pp: 1-1291.
21. Frackowiak. R, Ashburner. J, Penny. W, Zeki. S. Human Brain Function. The Wellcome Dept. of Imaging Neuroscience 2004; 2 Edition, ISBN: 0122648412,9780122648410.
22. Lang E.W, Tomé A.M, Keck I.R, Górriz-Sáez J.M, Puntonet C.G. Brain Connectivity Analysis: A Short Survey. Published online 2012; 1148(7), pp: 781-7.
23. Just M.A, Cherkassky V.L, Keller T.A.K, Kana R.K, Minshew N.J. Functional and Anatomical Cortical Underconnectivity in Autism: Evidence from an fMRI Study of Executive Function Task and Corpus Callosum Morphometry. Cerebral Cortex 2007; pp: 951-61.
24. Hull J.V, Dokovna L.B, Jacokes Z.J, Torgerson C.M, Irimia. A, Van Horn J.D. Resting-State Functional Connectivity in Autism Spectrum Disorders: A Review. Published NCBI 2017; pp: 205.
25. Tzourio-Mazoyer. N, Landeau. B, Papathanassiou. D, Crivello. F, Etard. O, et al. Automated Anatomical Labeling of Activations in SPM Using a Macroscopic Anatomical Parcellation of the MNI MRI Single-Subject Brain. Neuroimage 2002; vol.15, No.1, pp: 273-289.
26. Poli. R, Kennedy. J, Blackwell. T. Particle swarm optimization. Springer Science and Business Media 2007; pp: 1: 33-57.
27. Cortes. C, Vapnik. V. Support Vector Network. Mach Learn 1995; vol.20, pp: 273-297.
28. Ulfarsson M.O, Solo. V. A Semiparametric PCA Approach to fMRI Data Analysis. International Conference on Acoustics Speech and Signal Processing (ICASSP) 2010; pp: 634-637.