

# 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](mailto:h.hasani@tafreshu.ac.ir)



## بکارگیری کاهش ابعاد در تصاویر fMRI بر اساس الگوریتم فراابتکاری 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

دریافت: 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 تشدید مغناطیسی کارکردی (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) به‌عنوان یکی از ابزارهای قدرتمند جستجوی فراابتکاری در انتخاب ویژگی‌های بهینه بکار گرفته شده است. **مواد و روش‌ها:** به منظور ارزیابی قابلیت روش پیشنهادی، از الگوریتم آنالیز مولفه‌های اصلی (PCA) به‌عنوان یک روش کاهش 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 ارتباط عملکردی منجر به تولید فضای ویژگی با ۶۶۷۰ بعد می‌شود. **یافته‌ها:** دقت طبقه‌بندی کننده SVM در این فضای ویژگی ۵۶ درصد است. بکارگیری الگوریتم بهینه‌سازی توده ذرات با حذف ۳۴۴۲ ویژگی، دقت طبقه‌بندی را تا ۶۲/۱۹ درصد افزایش داد که در مقایسه با الگوریتم آنالیز مولفه‌های اصلی عملکرد بهتری دارد. نتایج کاهش ابعاد فضای ویژگی نشان می‌دهد که این الگوریتم فراابتکاری 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 تشدید 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 به‌عنوان یک روش تشخیصی شناخته شده است، طبقه‌بندی با روش‌های مختلف یادگیری ماشین از جمله ماشین‌های بردار پشتیبان، جنگل‌های تصادفی<sup>۸</sup> و نزدیکترین همسایگی<sup>۹</sup> 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<sup>۱۰</sup> 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 ۳۱۲ فرد مبتلا به اوتیسم و ۳۲۸ فرد سالم زیر بیست سال پرداخت. برای طبقه‌بندی از شبکه عصبی احتمالاتی<sup>۱۱</sup> استفاده کرد و به صحت تقریباً ۹۰ درصد رسید (۹). در سال ۲۰۱۶ کسرائیان فرد و همکاران به طبقه‌بندی داده‌های تصاویر fMRI حالت استراحت با استفاده از روش‌های طبقه‌بندی کننده ماشین‌های بردار پشتیبان مانند ماشین‌های بردار پشتیبان، شبکه‌های عصبی و رویکردهای رگرسیون پرداختند و صحت تقریبی بین ۶۰ تا ۷۰ درصد را ارائه دادند (۱۰). طی تحقیقاتی هاینزفلد 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<sup>۱۲</sup> ۶۳ درصد و شبکه عصبی عمیق (DNN)<sup>۱۳</sup> 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 ۳۰۰۰ ویژگی از نواحی مورد نظر مغز را استخراج کردند، سپس با استفاده از روش طبقه بندی 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 روانپزشک 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<sup>۱</sup> 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 تکنیک‌های کارا برای مطالعه تغییرات ارتباطات عملکردی نواحی مختلف مغز (در حالت فعالیت<sup>۲</sup> و یا در حالت استراحت<sup>۳</sup>) با بررسی تغییرات جریان و میزان اکسیژن خون<sup>۴</sup> است که اولین بار توسط آگوا مطرح شد (۳). این روش به دلیل ذات غیرتهاجمی، 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 تحریک مغز (در حالت فعالیت) ۲۵ درصد انرژی را مصرف می‌کند؛ بدین ترتیب مطالعه میزان عملکرد مغز در حالت استراحت به دلیل متابولیسم بیشتر انرژی و 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 را در مجموع ۶۰ درصد گزارش دادند. همچنین علت 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 پیش پیشانی<sup>۵</sup>، قشر گیجگاهی<sup>۶</sup> و قشر آهیانه‌ای<sup>۷</sup> 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 Mapping

2 Task

3 Rest

4 Blood Oxygenation Level Dependent (BOLD)

5 Prefrontal Cortex

6 Temporal Cortex

7 Parietal Cortex

8 Random Forests

9 KNN: K-Nearest Neighbor

10 Voxel

11 Probabilistic Neural Network (PNN)

12 Random Forests

13 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 خلاء 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 روش‌ها

برای انجام پژوهش حاضر، از تصاویر fMRI پایگاه داده 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<sup>۲۰</sup> 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 داده ABIDE استفاده شده است. این مجموعه شامل داده‌های جمع‌آوری شده از ۱۷ موسسه پژوهشی با ۸۲۰ نمونه 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 تشدید مغناطیسی ساختاری (sMRI)<sup>۲۱</sup> با حد تفکیک مکانی بالا و تصویر تشدید مغناطیسی 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.

استفاده از شبکه عصبی پرسپترون تک لایه<sup>۱۴</sup> ۱۰۳۵ داده تصاویر تشدید مغناطیسی 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 هاینزفلد حائز اهمیت است (۱۴، ۱۱). یکی از مشکلات اصلی در زمینه تجزیه و تحلیل تصاویر تشدید مغناطیسی 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<sup>۱۵</sup> 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<sup>۱۶</sup> ۸۰ درصد و تشخیص<sup>۱۷</sup> 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 به‌عنوان روش پیشنهادی ارائه دادند. رویکرد مهم این پژوهش افزایش صحت، تشخیص، پیش‌آگهی و راه‌های درمان اختلالات روانی مانند بیش‌فعالی (ADHD)<sup>۱۸</sup> و اوتیسم می‌باشد (۱۶). در پژوهش توماس و همکاران (۲۰۲۰) برای انعکاس مکانیسم تبادل اطلاعات بین نواحی مختلف مغز با استفاده از تصاویر حالت استراحت fMRI از شبکه عصبی کانولوشن سه بعدی (3D-CNN)<sup>۱۹</sup> استفاده کردند. علاوه



تصویر ۱- تصویر حالت استراحت fMRI

<sup>14</sup> ASD-DiagNet

<sup>15</sup> HC: Hierarchical Classification

<sup>16</sup> Sensitivity

<sup>17</sup> Specificity

<sup>18</sup> Attention Deficit Hyperactivity Disorder (ADHD)

<sup>19</sup> Three-Dimensional Convolutional Neural Network

<sup>20</sup> NP-hard

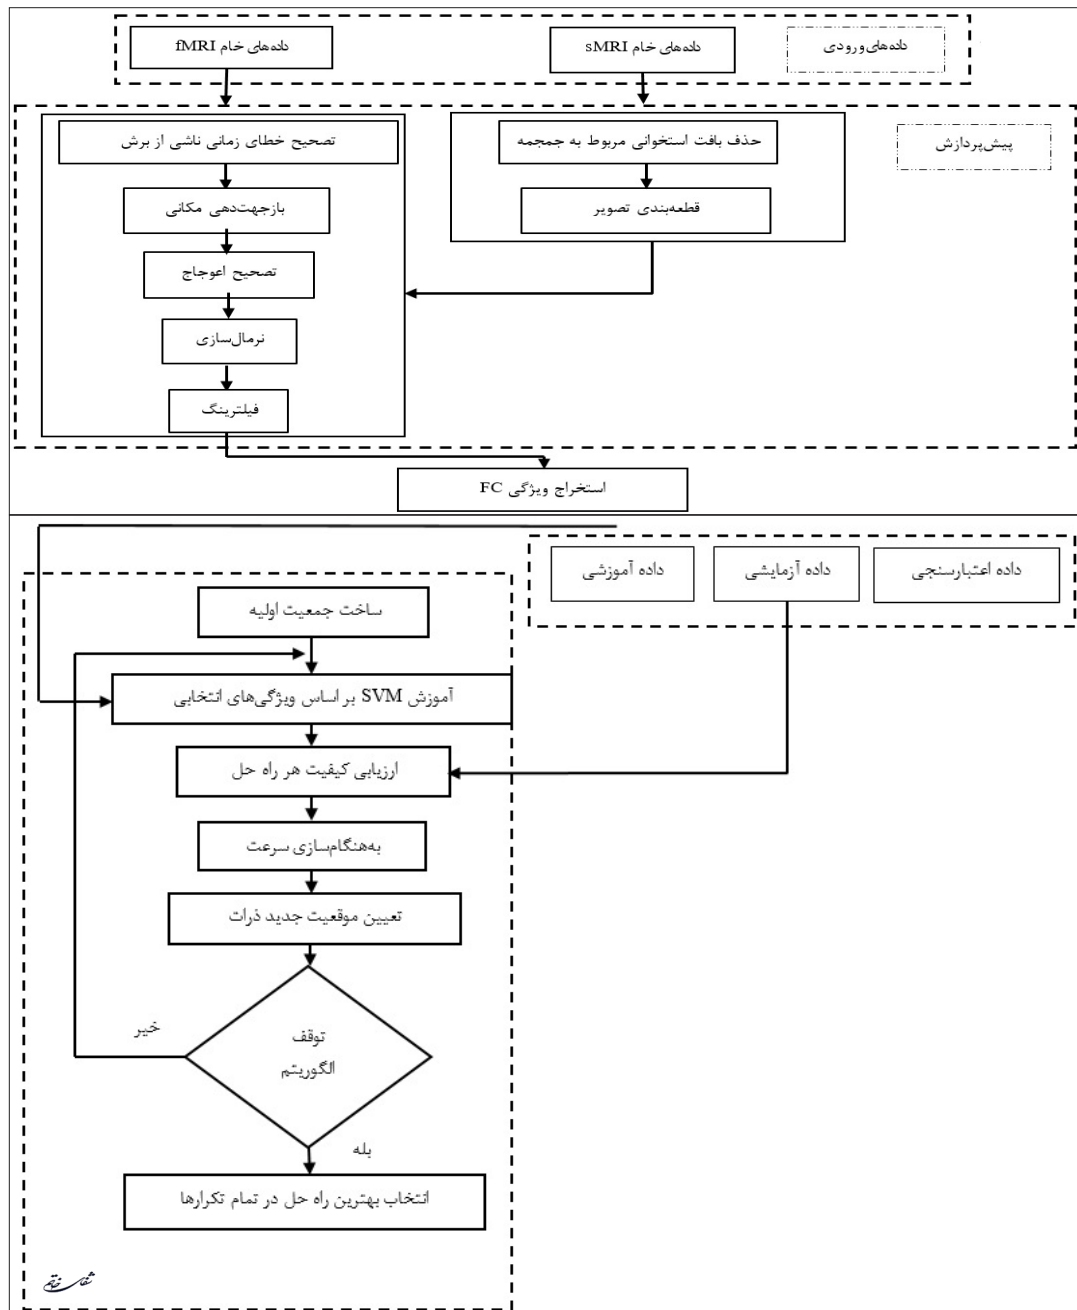
<sup>21</sup> Structural Magnetic Resonance Imaging (sMRI)

روش پیشنهادی

پیش پردازش تصاویر fMRI

از آنجائی که تصاویر sMRI نسبت به تصاویر fMRI دارای قدرت تفکیک مکانی بالاتری هستند، لذا از این تصاویر جهت بهبود قدرت تفکیک مکانی در مرحله پیش پردازش تصاویر fMRI استفاده می شود. تصاویر sMRI شامل استخوان جمجمه، چربی و پوست سر می باشند. چنانچه این قسمت ها حذف شوند، صحت نگاشت تصاویر نسبت به یکدیگر افزایش می یابد. به منظور

روش پیشنهادی از سه گام اصلی تشکیل شده که مراحل آن در فلوجارت تصویر ۲ نمایش داده شده است. در گام نخست بر روی داده های ورودی با هدف کاهش نویز و بهبود کیفیت تصویر یک پیش پردازش انجام می شود. سپس فضای ویژگی بر مبنای ماتریس ارتباط عملکردی ساخته شده و در نهایت ابعاد فضای ویژگی بهینه با استفاده از الگوریتم بهینه سازی توده ذرات تعیین می شود.



تصویر ۲- فلوجارت روش پیشنهادی

شماره پنجم

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<sup>۲۱</sup> 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.

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

در رابطه فوق، n تعداد تصاویر بدست آمده از کل مغز است.  $x_i(t)$  و  $x_j(t)$  به ترتیب، مقدار سیگنال سری زمانی در دو ناحیه i و j در زمان t است.  $\bar{x}_i$  و  $\bar{x}_j$  نیز میانگین سیگنال سری زمانی در این دو ناحیه می‌باشد. با توجه به در نظر گرفتن ۱۱۶ ناحیه در مغز، ۶۶۷۰ 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 فراابتکاری برای مجموعه داده‌های با حجم بالا موثرتر واقع شده است. الگوریتم‌های جستجوی فراابتکاری 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 فراابتکاری کارا می‌باشد که در سال ۱۹۹۵ توسط کندی و همکاران معرفی شد. این الگوریتم یکی از روش‌های بهینه‌سازی جمعیت-مبتنا 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<sup>۲۲</sup> 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<sup>۲۳</sup>: روش متداول برای اصلاح زمان‌بندی برش‌ها به این صورت است که یکی از برش‌ها به‌عنوان برش مرجع انتخاب می‌گردد و پس از شیفت دادن سیگنال سایر برش‌ها به سمت برش مرجع، اختلاف زمانی با استفاده از درون‌یابی تصحیح می‌گردد (۲۰). بازجهت‌دهی مکانی<sup>۲۴</sup>: حرکت سر باعث می‌شود که به هنگام تصویربرداری الزاماً یک واکسل یکسان 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<sup>۲۵</sup>: در این پژوهش با نگاشت تصاویر مغز به اطلس استاندارد MNI-۱۵۲، هر یک از نواحی را به خوبی می‌توان مشخص نمود (۲۱). نرمال‌سازی<sup>۲۶</sup>: در این مرحله، تمامی تصاویر سطح مقطع براساس سیستم مختصات استاندارد تراز می‌شوند. برای این منظور، تبدیلات خطی افاین<sup>۲۶</sup> 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<sup>۲۷</sup>: در این مرحله با استفاده از هموارسازی، میانگین تمام نقاط داده را نسبت به نقاط مجاور مورد محاسبه قرار می‌گیرد. فیلترینگ زمانی<sup>۲۸</sup>: از آنجائی 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 بهبود یابد (۲۱).

#### استخراج ویژگی بر اساس ارتباط عملکردی

با ایجاد نقشه ارتباطات عملکردی از مغز، عملکرد و همبستگی سری‌های زمانی بین نواحی مختلف مغز<sup>۲۹</sup> تعیین می‌شود. خروجی این روش، ماتریس ارتباط عملکردی مغز است که ضرایب همبستگی بین نواحی در آن قرار دارد (۲۴، ۲۲). در این پژوهش از الگوی برجسب گذاری (اطلس) خودکار آناتومیکی (ALL)<sup>۳۰</sup> که مغز انسان را به ۱۱۶ ناحیه تقسیم می‌کند، استفاده شده است (۲۵). به ازای هر ناحیه بر اساس میانگین‌گیری 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<sup>۳۳</sup> 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.  $w = w_{max} - t \times ((w_{max} - w_{min}) / Max_{iter})$  در این معادله،  $w$  مقدار وزن در تکرار  $t$  و  $Max_{iter}$  تعداد بیشینه تکرار است. همچنین  $w_{max}$  بیشترین میزان وزن اینرسی و  $w_{min}$  کمترین میزان وزن اینرسی را نشان می‌دهد. به منظور حفظ اندازه گام‌های ذرات، حداکثر و حداقل سرعت برای ذرات در نظر گرفته شد. پس از محاسبه سرعت طبق رابطه ۵، در صورتی 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  $[0,1]$  انتقال پیدا کند.

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

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

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

در این رابطه  $P_{ij}$  عددی تصادفی در محدوده  $[0,1]$  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 به‌عنوان نتیجه نهایی انتخاب می‌شود.

#### یافته‌ها

به منظور ارزیابی قابلیت روش پیشنهادی، از تصاویر fMRI پایگاه داده ABIDE استفاده شده است. در 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 به‌عنوان 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 متناظر 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 نظارت‌شده 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 به‌عنوان تابع هدف استفاده شده است.

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

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

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

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 شده است. FN و 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. به منظور به هنگام‌سازی موقعیت هر ذره طبق رابطه (۵) بردار سرعت اعضای جمعیت به‌روزرسانی می‌شود.

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

در این رابطه پارامترهای  $V_{ij}$  و  $X_{ij}$  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 نشان‌دهنده 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  $[0,1]$  می‌باشند. پارامتر  $w$  وزن اینرسی است که در تکرارهای الگوریتم متغییر در نظر گرفته می‌شود. در تکرار اولیه برای افزایش

<sup>33</sup> Exploration

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


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

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 ۶ درصد بر روی داده تست و ۳ 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 فراابتکاری توده ذرات و طبقه‌بندی کننده ماشین‌های بردار پشتیبان جهت انتخاب زیرمجموعه‌ای از ویژگی‌های بهینه برای تشخیص اختلال طیف اوتیسم استفاده شد. مقادیر پارامترهای الگوریتم بهینه‌سازی توده ذرات در جدول ۲ آورده شده است.

جدول ۲- مقادیر پارامترهای الگوریتم بهینه‌سازی توده ذرات


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



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

جدول ۳- مقایسه طبقه‌بندی کننده‌ها

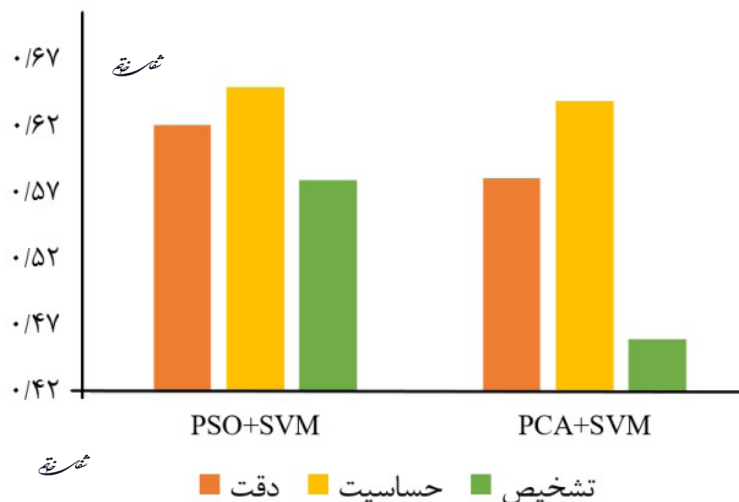
داده اعتبارسنجی			داده تست			تعداد ویژگی‌ها	نوع طبقه‌بندی کننده
تشخیص	حساسیت	صحت	تشخیص	حساسیت	صحت (درصد)		
۰/۱۶۶	۰/۱۵۶	۶۰/۱۹۷	۰/۱۵۲	۰/۱۵۹	۵۶/۰۹	۶۶۷۰	ماشین‌های بردار پشتیبان
۰/۱۷۱	۰/۱۶۷	۶۳/۴۱	۰/۱۵۸	۰/۱۶۵	۶۲/۱۹	۳۲۲۸	نزدیک‌ترین همسایگی



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 فضا با توجه به مقادیر ویژه متناظر با هر مولفه اصلی، العاد فضا 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 توانست صحت طبقه‌بندی کننده را شش درصد ارتقاء دهد. همچنین نتایج بیانگر توانایی 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 به‌عنوان یک روش استاندارد در حوزه کاهش ابعاد فضا 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 پزشکی دارای حجمی بالا می‌باشند. با توجه به گسترده بودن الگوریتم‌های فراابتکاری و کارایی آن‌ها در کاهش حجم ویژگی‌های استخراج شده، پیشنهاد می‌شود از سایر الگوریتم‌های فراابتکاری 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 پزشکی، 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 بر مبنای الگوریتم‌های فراابتکاری بهینه‌سازی توده ذرات در طبقه‌بندی افراد اوتیستیک و سالم بر مبنای تصاویر fMRI ارائه شد. نتایج بدست آمده نشان داد، الگوریتم بهینه‌سازی توده ذرات با حذف بیش از نیمی از ویژگی‌های استخراج شده از

### منابع

- 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.
- Savoy R.L. History and Future Directions of Human Brain Mapping and Functional Neuroimaging. Elsevier Science B.V 2001; pp: 9-42.
- 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.
- 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.
- 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.
- 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.
- Plitt. M, Barnes K.A, Martin. A. Functional Connectivity Classification of Autism Identifies Highly Predictive Brain Features but Falls Short of Biomarker Standards. NeuroImage: Clinical 2015; vol.7, pp: 359-366.
- Friston K.J. Functional and Effective Connectivity in Neuroimaging: A Synthesis. Hum. Brain Mapp 1994; vol.2, pp: 56-78.
- Iidaka. T. Resting State Functional Magnetic Resonance Imaging and Neural Network Classified Autism and Control. Cortex 2015; vol.63, pp: 55-67.
- Kassraian Fard. P, Matthis. 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/fpsy.2016.00177.
- 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.
- 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.
- 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/fpsy. 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 an 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.