

# تشخیص کم‌توجهی - بیش‌فعالی (ADHD) مبتنی بر الگوریتم تکاملی با طول متغیر

مریم رضانیان کشتلی و حسین منتظری کردی

درمان به موقع این بیماری از بسیاری جهات حایز اهمیت است. این نوع رفتار کودکان بر روی عملکرد آنها در خانواده، اجتماع و مدرسه تأثیر نامطلوب می‌گذارد و سبب بروز واکنش‌های منفی می‌گردد. در نهایت، این عارضه سبب کاهش اعتماد به نفس، احساس بی‌کفایتی، اختلالات ارتباطی، مشکلات تحصیلی، اضطراب، افسردگی و بزهکاری در این کودکان می‌گردد [۱] و [۲].

یکی از راه‌های تشخیص این بیماری، بررسی عملکرد مغز می‌باشد. تا کنون روش‌های مختلفی همانند الکتروانسفالوگرافی، مگنتوانسفالوگرافی و مقطع‌نگاری انتشار پوزیترون برای تعیین محل وقوع فعالیت‌های عصبی و ارتباطات نواحی مختلف مغز مورد استفاده قرار گرفته‌اند [۳].

در سال‌های اخیر، روش تصویرنگاری عملکردی تشدید مغناطیسی (fMRI) بیش از سایرین برای تشخیص نواحی و ارتباطات موجود بین آنها در مغز به کار گرفته شده است. این روش به عنوان یک ابزار غیر تهاجمی، دارای وضوح زمانی قابل قبول و بیشینه وضوح مکانی (در حد ۳ میلی‌متر) در مقایسه با سایر روش‌ها می‌باشد. برخلاف روش تصویرنگاری MRI که برای مطالعه ساختار فیزیکی بدن استفاده می‌شود، fMRI تنها در مطالعات مربوط به عملکرد مغز، تصاویر متعددی با وزن  $T_2^*$  در فواصل زمانی معین ثابت و با وضوح کمتر تهیه می‌کند. وقوع فعالیت‌های عصبی در مغز، با فرایندهای فیزیولوژیکی متفاوت در بدن، سبب ایجاد تغییراتی در پارامترهای فیزیکی بافت مغز می‌شوند. یکی از این تغییرات، تغییر مقدار اکسیژن موجود در خون می‌باشد. در تصویرنگاری عملکردی تشدید مغناطیسی در حالت استراحت<sup>۲</sup> (rs-fMRI) شدت روشنایی تصاویر fMRI تابعی از مقدار اکسیژن موجود در خون بوده و سیگنال وابسته به سطح اکسیژن خون<sup>۳</sup> (BOLD) نام دارد [۴].

هدف از انجام این تحقیق، بهبود دقت تشخیص افراد سالم از بیمار مبتنی بر تحلیل سیگنال BOLD تصاویر rs-fMRI دو گروه می‌باشد. تا کنون پژوهش‌های متعددی در محث تشخیص اختلال کم‌توجهی - بیش‌فعالی انجام شده و مقالات مختلفی در این زمینه منتشر شده است. نخستین بار ژو و همکارانش با استفاده از تکنیک تجزیه و تحلیل مؤلفه اصلی و ویژگی یکنواختی محلی نواحی مغز توانستند افراد سالم را از بیماران مبتلا به اختلال کم‌توجهی - بیش‌فعالی تفکیک نمایند [۵].

چنگ و گروه مطالعاتی او ابتدا ویژگی‌های دامنه نوسانات فرکانس پایین مغز، یکنواختی نواحی مغز و اتصالات عملکردی در سطح واکسل و در سطح نواحی را از سیگنال BOLD استخراج نمودند. سپس افراد بیمار مبتلا به اختلال کم‌توجهی - بیش‌فعالی را از گروه‌های سالم مبتنی بر این ویژگی‌ها طبقه‌بندی کردند. آنان با استفاده از این ویژگی‌ها و با کمک

چکیده: روش‌هایی که امروزه برای بررسی ارتباطات مغز به منظور تشخیص بیماری‌های مرتبط با عملکرد مغز استفاده می‌شود، روش تصویرنگاری عملکردی تشدید مغناطیسی در حالت استراحت می‌باشد. در این مقاله، یک روش جدید با استفاده از الگوریتم تکاملی با طول متغیر برای انتخاب ویژگی‌های مناسب جهت بهبود دقت تشخیص افراد سالم و بیمار به اختلال کم‌توجهی - بیش‌فعالی از یکدیگر مبتنی بر تحلیل تصاویر rs-fMRI ارائه شده است. ویژگی‌های مورد بررسی مقادیر همبستگی میان سیگنال‌های سری زمانی مناطق مختلف مغز می‌باشند. انتخاب ویژگی با طول متغیر بر اساس الگوریتم زنبور عسل جهت غلبه بر مشکل انتخاب ویژگی در الگوریتم‌های با طول بردار و ویژگی ثابت صورت گرفت. فاصله ماهالانویس به عنوان تابع ارزیابی الگوریتم زنبور عسل استفاده شده است. کارایی الگوریتم از لحاظ مقدار تابع ارزیابی در درجه اول و زمان پردازش در درجه دوم مورد بررسی قرار گرفته شد. نتایج به دست آمده از کارایی به مراتب بالاتر الگوریتم زنبور عسل با طول متغیر نسبت به سایر روش‌های انتخاب ویژگی حکایت دارد. در حالی که بهترین نتیجه صحت طبقه‌بندی کلی در میان سایر روش‌ها با ۲۶ ویژگی منتخب از الگوریتم اجتماع ذرات، ۷۶٫۶۱٪ می‌باشد، روش پیشنهادی توانسته به مقدار صحت طبقه‌بندی کلی ۸۵٫۳۲٪ با انتخاب ۲۵ ویژگی دست یابد. طبیعت داده به صورتی است که افزایش تعداد ویژگی‌ها منجر به بهبود بیشتر صحت طبقه‌بندی می‌شود به گونه‌ای که با افزایش طول بردار ویژگی به ۳۵ و ۴۵ صحت طبقه‌بندی به ترتیب به ۹۱٫۶۶٪ و ۹۵٫۵۷٪ رسیده است.

کلیدواژه: تصویربرداری تشدید مغناطیسی حالت استراحت، بیماری ADHD، انتخاب ویژگی، الگوریتم تکاملی با طول متغیر، فاصله ماهالانویس، طبقه‌بندی.

## ۱- مقدمه

اختلال کم‌توجهی - بیش‌فعالی<sup>۱</sup> (ADHD) اختلالی است که ۳ تا ۵٪ کودکان به آن مبتلا هستند و سبب پرتحرکی، بی‌توجهی و رفتارهای ناگهانی بیشتر و شدیدتری نسبت به کودکان دیگر در آنها می‌شود. بر اساس نوع علائم بیماران مبتلا، ADHD به سه گروه نوع بی‌توجه، نوع پرتحرکی/ تکانشی و نوع ترکیبی تقسیم می‌شوند. نقص در تکامل سیستم اعصاب یکی از مهم‌ترین علل ایجاد این اختلال در کودکان است. این نقص به احتمال زیاد در قسمت‌هایی از مغز که مسئول توجه، تمرکز و تنظیم فعالیت‌های حرکتی است ایجاد می‌شود. مشکل اساسی این کودکان، عدم توانایی آنها در حفظ و تنظیم رفتارشان است. تشخیص و

این مقاله در تاریخ ۳ آذر ماه ۱۳۹۷ دریافت و در تاریخ ۲۰ خرداد ماه ۱۳۹۸ بازنگری شد.

مریم رضانیان کشتلی، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران، (email: maryamramzaniyan@stu.nit.ac.ir).  
حسین منتظری کردی (نویسنده مسئول)، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران، (email: hmontazery@nit.ac.ir).

1. Attention-Deficit/Hyperactivity Disorder

2. Rest State-Functional Magnetic Resonance Image

3. Blood Oxygenation Level Dependent

ویژگی‌های مقادیر همبستگی بین نواحی مغز سیگنال BOLD و طبقه‌بند ماشین بردار پشتیبان استفاده کردند. این روش توانست با ۲۶ ویژگی منتخب به دقت ۷۶/۶۱٪ در جداسازی افراد سالم از بیمار دست یابد. همچنین این روش توانسته به ترتیب ۷۲/۷۳٪ و ۷۱/۷۷٪ افراد بیمار را به درستی در گروه افراد سالم قرار دهد [۳].


معایب عمده روش‌های پیشین شامل به کارگیری تعداد نمونه‌های کم، تصاویر یک ملیت، درصد تشخیصی حساسیت و قطعیت بالای تنها یک گروه از افراد (سالم یا بیمار) می‌باشند. در این تحقیق، تعداد نمونه‌های تصاویر زیاد شامل ملیت‌های مختلف نظیر چینی، آمریکایی و اروپایی مورد تحلیل قرار گرفتند [۳]. ویژگی‌های مقادیر همبستگی نواحی مختلف مغز از سیگنال BOLD استخراج گردید. سپس یک روش انتخاب ویژگی مبتنی بر الگوریتم تکاملی با طول متغیر بر پایه الگوریتم زنبور عسل توسعه داده شد و تعداد ۲۵ ویژگی از میان ۶۶۷۰ ویژگی همبستگی انتخاب شدند. در نهایت، ویژگی‌های منتخب با قدرت تفکیک‌پذیری بهتری نسبت به روش‌های پیشین قادر به تشخیص نمونه‌های گروه بیمار از سالم گردید.

## ۲- روش بررسی

بررسی ارتباط میان نواحی مختلف مغز با استفاده از تصاویر fMRI نیازمند طبقه‌بندی خودکار می‌باشد که برای آن، دو کار باید صورت پذیرد: (۱) تحلیل ویژگی و (۲) طبقه‌بندی. تحلیل ویژگی شامل دو بخش استخراج ویژگی و انتخاب ویژگی می‌باشد. جهت بهبود نرخ تشخیص بیماری، مهم‌ترین مرحله استخراج و انتخاب ویژگی‌های مهم مربوط به بیماری است که در این تحقیق، روی این مرحله مهم تمرکز می‌شود. شکل ۱ شمای کلی الگوریتم استفاده‌شده را نمایش می‌دهد که در ادامه قسمت‌های مختلف آن توضیح داده می‌شود.

### ۱-۲ استخراج ویژگی

در این تحقیق، مجموعه دادگان حاصل از تصاویر rs-fMRI مربوط به یک رقابت بین‌المللی (۲۰۰-ADHD) در سال ۲۰۱۱ میلادی استفاده شدند [۱۱]. مشخصات این مجموعه دادگان در جدول ۱ آورده شده است. همبستگی سری زمانی مناطق مختلف مغز از تصاویر rs-fMRI یکی از ویژگی‌های معمول مورد استفاده می‌باشد. تعداد این مناطق وابسته به تصویر الگویی است که در مرحله عملیات پیش‌پردازش تصاویر به کار رفته است. در این پژوهش، الگوی برجسب‌گذاری خودکار ساختاری (AAL) استفاده شده است. این الگو مغز انسان را به ۱۱۵ ناحیه تقسیم‌بندی می‌کند [۱۲]. با محاسبه همبستگی دوه‌دوی این مناطق، تعداد ۶۶۷۰ ضریب همبستگی وجود خواهد داشت که این تعداد بسیار بیشتر از تعداد کل دادگان آموزشی می‌باشد. این مسئله خود به تنهایی برای درک اهمیت این مرحله از پردازش و انتخاب صحیح ویژگی‌ها کفایت می‌کند. برای اندازه‌گیری همبستگی میان این مناطق، روش‌های متفاوتی وجود دارد. در این مقاله برای محاسبه این ضرایب در یک فرد، ابتدا میانگین سیگنال BOLD واکسل‌های هر ناحیه محاسبه گردید. سپس با کنار هم قرار دادن کلیه تصاویر حجم کامل مغز همان فرد، سیگنال سری زمانی این مناطق به دست آورده شد. یعنی در واقع ۱۱۵ سیگنال که به تعداد تصاویر حجم کامل مغز از آنها نمونه‌برداری شده



شکل ۱: نمودار بلوکی کلی سیستم تشخیص اختلال کم‌توجهی- بیش‌فعالی (ADHD) مبتنی بر سیگنال BOLD حاصل از تصاویر rs-fMRI.

ماشین بردار پشتیبان موفق شدند ۸۵/۱۱٪ از افراد سالم را به درستی در گروه افراد سالم قرار داده و صحت تشخیص روش آنها ۷۶/۱۵٪ بوده است [۶].

توماسی و گروهش با اندازه‌گیری شدت اتصالات عملکردی میان واکسل‌های موجود در هر ناحیه و نیز شدت اتصالات عملکردی بین نواحی مختلف مغز به عنوان ویژگی نشان دادند که کودکان مبتلا به بیماری ADHD در مناطق مربوط به مخچه، قشر آهیانه فوقانی مغز و نیز شبکه حالت پیش‌فرض مغز، اتصالات عملکردی ضعیف‌تری دارند و در مناطق مربوط به عواطف و شور و شوق آنها، اتصالات قوی‌تری وجود دارد [۷].

لویان و همکارانش نیز با ارائه مدلی برای تشخیص بر مبنای ویژگی تصاویر MRI معمولی، اتصالات عملکردی و برخی دیگر از ویژگی‌های شخصیتی همانند میزان بهره‌هوشی (IQ)، افراد سالم و بیمار را از هم تفکیک نمودند. آنها با استفاده از روش‌های مختلفی همانند الگوریتم تصادفی جنگل، شکل‌شناسی مبتنی بر واکسل‌ها و نیز ماشین بردار پشتیبان توانستند ویژگی‌های متمایزکننده گروه سالم از بیمار را تا حد زیادی پیدا کنند و با استفاده از این ویژگی‌ها، به دقت ۹۴٪ در جداسازی افراد سالم از بیمار دست یابند اما این روش در جداسازی افراد بیمار چندان دقیق عمل نکرد و تنها توانست ۲۱٪ از افراد بیمار را به درستی، بیمار تشخیص دهد [۸].

در تحقیقی دیگر، ویژگی‌های یکنواختی نواحی مغز، ضخامت قشر مغز و اتصالات عملکردی برای تشخیص اختلال کم‌توجهی- بیش‌فعالی مورد استفاده قرار گرفت. در ابتدا به وسیله هر کدام از این ویژگی‌ها، به صورت جداگانه به تفکیک افراد پرداخته شد. در این حالت، بالاترین درصد موفقیت با استفاده از ویژگی اتصال عملکردی و به میزان ۵۳/۲٪ به دست آمده است. در مرحله بعد، این کار با استفاده از تمامی این ویژگی‌ها صورت گرفت. میزان صحت طبقه‌بندی در این حالت، ۵۴/۱٪ گزارش شده است [۹]. کائو و گروهش با استفاده از معیار ReHo به تشخیص ADHD پرداختند [۱۰]. این معیار بر اساس این فرضیه استوار است که واکسل‌های مجاور در یک ناحیه فعال مغز تحت شرایط خاص فعالیت سوخت و ساز خود را با یکدیگر همگام می‌کنند و از این معیار به منظور بررسی هماهنگی عملکرد یک واکسل و نزدیک‌ترین واکسل‌های همسایه آن استفاده شده است. آنها مقدار ReHo را با استفاده از ضریب هماهنگی کندال (KCC) محاسبه نمودند و نشان داده شد افرادی که دچار بیماری ADHD هستند نسبت به افراد سالم در مناطق مربوط به بینایی، مقادیر ReHo بیشتری دارند و در برخی نواحی دیگر مغز، مقادیر ReHo کمتری دارند.

در نهایت آقای یوسفی و گروهش در تحقیقی دیگر به منظور تشخیص بیماری ADHD از الگوریتم ازدحام ذرات (PSO) برای انتخاب ویژگی از

جدول ۱: مجموعه تصاویر ۲۰۰-ADHD.

استفاده به عنوان	تعداد کل	تعداد افراد سالم	تعداد ADHD- Hyperac/Impulsive	تعداد ADHD- Combined	تعداد ADHD- Inattentive	کشور	نماد	نام دانشگاه یا موسسه
آموزش آزمایش	۸۳	۶۱	۱	۱۶	۵	آمریکا	KKI	Kennedy Krieger Institute
آموزش آزمایش	۲۱۶	۹۸	۲	۷۳	۴۳	آمریکا	NYU	New York University Child Study Center
آموزش آزمایش	۷۹	۴۲	۲	۲۳	۱۲	آمریکا	OHSU	Oregon Health & Science University
آموزش آزمایش	۸۹	۸۹	۰	۰	۰	آمریکا	UP	University of Pittsburgh
آموزش	۵۹	۵۹	۰	۰	۰	آمریکا	WU	Washington University in St. Louis
آموزش آزمایش	۱۹۴	۱۱۶	۰	۲۹	۴۹	چین	PU	Peking University
آموزش آزمایش	۴۸	۲۳	۶	۱۸	۱	هلند	NI	Neuro IMAGE Samples
جمع	۷۶۸	۴۸۸	۱۱	۱۵۹	۱۱۰			

ضرورت جستجوی فضای ویژگی با طول‌های متفاوت مطرح می‌گردد. با فرض دانستن طول بردار ویژگی مطلوب، برای انتخاب زیرمجموعه  $L$  عضوی مطلوب (با فرض مشخص بودن  $L$ ) از یک مجموعه  $M$  عضوی، تعداد زیرمجموعه‌های مورد بررسی برابر ترکیب  $\binom{M}{L}$  می‌باشد. این مسأله خود گواه بر حجم محاسباتی بالای فضای جستجو است. بنا بر دلایل مطرح‌شده، الگوریتم‌های فرابتنکاری مورد استفاده در حل مسایل بهینه‌سازی برای جستجوی زیرفضای ویژگی به کار گرفته شدند [۱۷].

الگوریتم زنبور عسل همانند الگوریتم ژنتیک [۱۸]، ازدحام ذرات [۱۹] و الگوریتم قطره آب [۲۰] که در مسایل انتخاب ویژگی از آنها استفاده گردیده است، جزء الگوریتم‌های تصادفی و مبتنی بر جستجوی زیرفضای بهینه می‌باشد. این الگوریتم شبیه‌سازی رفتار جستجوی غذا توسط زنبوران یک کندو است. به دلیل بزرگ بودن فضای جستجو، برای یافتن مجموعه زیربهینه، توسط این الگوریتم زیرفضاهای موجود را به صورت تصادفی و بر مبنای ارتقای جواب‌های حاصل در هر مرحله به دست می‌آوریم. به دلیل نداشتن اطلاع صحیح از میزان طول بردار ویژگی مطلوب، ما بر آن شدیم تا در این مقاله به جای استفاده از الگوریتم زنبور عسل با طول ثابت، بهبود یافته آن را با عنوان الگوریتم زنبور عسل با طول متغیر برای جستجوی تصادفی و پوشش زیرمجموعه‌های موجود معرفی نماییم.

### ۲-۳ الگوریتم تکاملی با طول متغیر

یکی از مشکلات اساسی مسئله انتخاب ویژگی عدم دانش در مورد طول بردار ویژگی نهایی می‌باشد. در برخورد با مسأله انتخاب ویژگی با طول ثابت در الگوریتم زنبور عسل همانند مسایل بهینه‌سازی توابع برخورد می‌کنیم بدین گونه که تعداد ویژگی‌های انتخاب شده ثابت و برابر با تعداد متغیرها در مسایل بهینه‌سازی متغیرها می‌باشند.

در مسایل بهینه‌سازی، اعدادی که جایگزین متغیرها می‌شوند تا در نهایت جواب زیربهینه را نتیجه دهند، همانند تغییر دادن ویژگی‌هایی می‌باشند که در مسایل انتخاب ویژگی در الگوریتم زنبور عسل با طول ثابت به کار می‌روند. بنابراین باید دقت داشت که طول بردار ویژگی مورد نظر همچنان ثابت می‌ماند و تنها ویژگی‌های منتخب جابه‌جا می‌شود. همانند توابع بهینه‌سازی، مقادیر حقیقی در متغیرها جایگزین می‌گردند که این مقادیر معادل با ویژگی انتخاب شده از بردار ویژگی اصلی می‌باشد.

با فرض این که  $L$  طول زیرمجموعه‌های بردار ویژگی مطلوب است، در گام اول  $SN$  منبع غذایی (جواب اولیه) را با اندازه  $L$  ویژگی به

است. سپس ضرایب همبستگی پیرسون مطابق (۱) برای مناطق مختلف مغز محاسبه شد [۱۳]

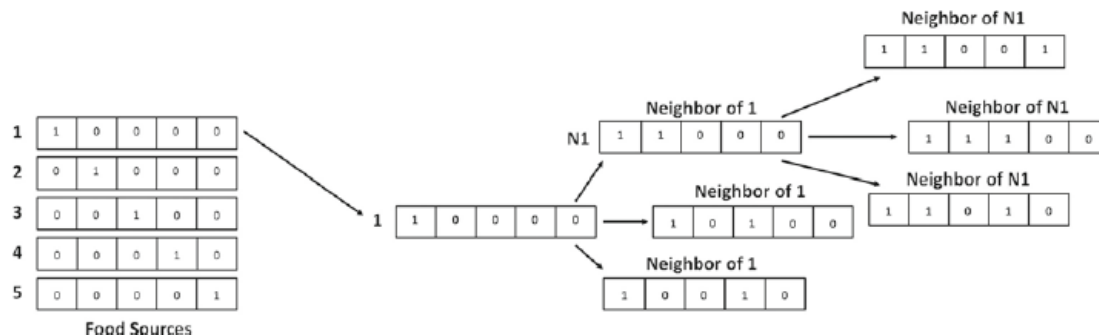
$$r_{ij} = \frac{\sum_{t=1}^n ([x_i(t) - \bar{x}_i] \times [x_j(t) - \bar{x}_j])}{\sqrt{\sum_{t=1}^n ([x_i(t) - \bar{x}_i]^2) \times \sum_{t=1}^n ([x_j(t) - \bar{x}_j]^2)}} \quad (1)$$

در رابطه بالا،  $n$  تعداد تصاویر حجم کامل مغز و  $x_i(t)$  و  $x_j(t)$  به ترتیب مقدار سیگنال در دو ناحیه  $i$  و  $j$  در زمان  $t$  می‌باشد.  $\bar{x}_i$  و  $\bar{x}_j$  نیز میانگین سیگنال سری زمانی در این دو ناحیه است. این مشخصه‌ها در یک بردار موسوم به بردار ویژگی کنار هم قرار می‌گیرند.

بدین ترتیب مجموعه داده شامل ۷۶۸ نمونه می‌باشد که از نمونه تصاویر rs-fMRI در مغز افراد مبتلا به بیماری اختلال کم‌توجهی- بیش‌فعالی (گروه بیمار) و اشخاص سالم بدون عارضه (گروه کنترل یا سالم) تهیه شده است. این ۷۶۸ نمونه به تفکیک شامل ۲۸۰ نمونه بیمار به اختلال کم‌توجهی- بیش‌فعالی و ۴۸۸ نمونه سالم می‌باشد که به طور جداگانه ۶۶۷۰ ویژگی همبستگی از هر سیگنال استخراج می‌شود. سیگنال‌های سری زمانی تصاویر رقابت ۲۰۰-ADHD از پایگاه داده معتبر بوده و توسط محققان زیادی مورد استفاده قرار گرفته است [۱۴].

### ۲-۲ انتخاب ویژگی

در مواردی که تعداد نقاط ویژگی از تعداد نمونه‌ها خیلی بیشتر است انتخاب ویژگی حایز اهمیت خواهد بود زیرا استفاده از تمام ویژگی‌ها غیر عملی بوده و موجب کاهش کارایی مدل می‌گردد. از این رو هر نوع روش توسعه یافته‌ای که توانایی استخراج الگوهای با قدرت تفکیک‌پذیری بالا و حداقل تعداد ویژگی لازم از این فضای اطلاعاتی ابعاد بالا را داشته باشد، یک رهیافت داده‌کاوی نامیده می‌شود [۱۵]. انتخاب ویژگی در حقیقت مسئله انتخاب یک زیرمجموعه از ویژگی‌ها است که برای توضیح هدف مورد نظر کافی و ضروری می‌باشد. از جمله مزایای فرایند انتخاب ویژگی<sup>۱</sup> می‌توان به افزایش دقت و سرعت در اجرای تکنیک‌های پیش‌بینی، حذف داده‌های غیر مرتبط و اضافه و افزایش قابلیت فهم‌پذیری مدل‌های مورد استفاده اشاره نمود. از جمله مسایل مهم دیگر در این زمینه می‌توان به نداشتن اطلاعات درست و صحیحی از اندازه ابعاد بردار ویژگی که قابلیت توصیف کامل داده به منظور مشخص نمودن کلاس آن داده نسبت به کلاس‌های دیگر را دارا باشد، اشاره نمود [۱۶]. با دانستن این مطلب،



شکل ۲: طرحی از مکانیزم جستجو و شناسایی همسایگی در الگوریتم زنبور عسل بهبودیافته.

متفاوت وجود دارد. این موضوع، محدودیت ندانستن این که چه طولی از بردار ویژگی انتخابی قابلیت دسته‌بندی مطلوب را امکان‌پذیر می‌سازد، را تا حد قابل قبولی مرتفع می‌کند. شکل ۲ طرحی از مکانیزم جستجوی روش پیشنهادی در الگوریتم زنبور عسل بهبودیافته را نشان می‌دهد. مراحل اصلی الگوریتم پیشنهادی به صورت زیر خواهد بود:

- (۱) بردارهای ویژگی با طول متغیر را به عنوان جواب اولیه تولید می‌کنیم.
- (۲) مقدار برازش جواب‌های اولیه با تابع ارزیاب محاسبه می‌شود.
- (۳) جواب‌های همسایه پاسخ‌های اولیه تولید می‌شوند.
- (۴) به مرحله ۲ رفته و مقدار برازش جواب‌های همسایه را محاسبه می‌کنیم.
- (۵) تا زمانی که شرط توقف برآورده نشود مراحل زیر تکرار می‌شوند.
- (۶) برای  $i = 1, \dots, SN$
- (۷) اگر برازش جواب‌های همسایه بهتر باشد، جایگزین جواب قبلی شود.
- (۸) وگرنه آن را کنار گذاشته و پاسخ جدید را تولید می‌کنیم.
- (۹) عمل تولید جواب‌های اولیه تا رسیدن به max limit ادامه می‌یابد.
- (۱۰) در صورت محقق نشدن همسایه بهتر، آخرین جواب ذخیره می‌شود.
- (۱۱) بهترین منبع غذایی ذخیره می‌شود.
- (۱۲) طول بهترین جواب مشخص می‌شود.
- (۱۳) جواب‌های اولیه جدید با طول مرحله قبلی تولید می‌شوند.
- (۱۴) به مرحله ۳ رفته و تا برآورده شدن شرط توقف، مراحل قبلی را ادامه می‌دهیم.
- (۱۵) پس از برآورده شدن شرط توقف، بهترین جواب به عنوان بردار ویژگی نهایی انتخاب می‌شود.

در این الگوریتم توانایی جستجو به جلو و عقب وجود دارد. به استثنای تعیین شرطی برای زنبورهای پیشرو که جواب تصادفی آنان با مقادیر کمتری از ویژگی‌ها ساخته می‌شود، باقی الگوریتم به صورت یکسان با الگوریتم زنبور عسل با طول ثابت می‌باشد. چون نشان داده شده که بردارها با ویژگی‌های کمتر، درصد طبقه‌بندی بیشتر و باعث کاهش زمان پردازش در مراحل بعدی می‌شوند، ما بر آن شدیم که از این شرط در الگوریتم خود استفاده کنیم.

### ۳- نتایج کار

در این قسمت، نتایج حاصل از اجرای روش پیشنهادی بر روی تصاویر آموزشی مربوط به رقابت بین‌المللی ADHD-۲۰۰ ارائه گردید. با توجه به تعداد کم نمونه‌ها، روش ارزیابی متقابل چرخشی جهت جلوگیری از ایجاد هر گونه بایاس و خطا هنگام انتخاب ویژگی و طبقه‌بندی استفاده شده است. جهت انجام مراحل مختلف شبیه‌سازی، داده‌های ورودی ۱۰ بار به طور تصادفی به دو مجموعه یادگیری و آزمون تقسیم می‌شوند.

صورت تصادفی پدید می‌آوریم. سپس جواب‌های اولیه پدیدآمده را به تابع ارزیاب می‌دهیم تا میزان شایستگی هر جواب را به عنوان یکی از پاسخ‌های مسأله ارزیابی کند. در گام بعدی با استفاده از (۲) جواب‌های جدیدی را پدید می‌آوریم

$$V_{ij} = x_{ij} + \phi_{ij} (x_{ij} - x_{kj}) \quad (2)$$

که در رابطه بالا  $\phi_{ij}$  و  $k = 1, \dots, SN, j = 1, \dots, D, i = 1, \dots, SN$  یک عدد تصادفی در بازه  $[-1, 1]$  می‌باشند. پارامتر  $SN$  تعداد منابع غذایی،  $D$  تعداد پارامترهای بهینه‌سازی و  $k$  هرچند که به صورت تصادفی انتخاب می‌گردد، اما مقدار آن متفاوت از  $i$  است. همانند مرحله قبلی، این جواب‌ها به تابع ارزیاب رفته و میزان شایستگی آنها مشخص می‌گردد. در گام بعدی، جواب‌ها با یکدیگر مقایسه می‌گردند. اگر جواب حاصل در گام فعلی نسبت به گام قبلی از شایستگی بالاتری برخوردار بود، این جواب به عنوان جواب بهتر ذخیره شده و جواب قدیمی را کنار می‌گذارد. در صورتی که جواب حاصل در مرحله قبل بهتر از جواب حاصل در مرحله فعلی باشد، جواب فعلی را کنار گذاشته و به ذخیره جواب قبلی می‌پردازد. شایان ذکر است که الگوریتم زنبور عسل علاوه بر تعداد جواب‌های اولیه که توسط کاربر مشخص می‌گردد، دارای دو پارامتر کنترلی دیگر به نام‌های max limit و number of iteration می‌باشد. پارامتر اول برای جلوگیری از افتادن مسأله در حالات بهینه محلی می‌باشد. زمانی که جواب‌های مسأله در هر گام تا رسیدن به مقدار پارامتر max limit شایستگی بیشتری را کسب نکرده باشند، این پاسخ‌ها به طور کلی رها شده و جواب اولیه‌ای را به صورت تصادفی پدید می‌آورد و مراحل قبلی را عیناً بر روی آن پیاده‌سازی می‌کند. این مراحل تا زمانی که الگوریتم به شرط خاتمه (برآورده کردن خواسته مسأله و یا مقدار پارامتر number of iteration تعیین شده توسط کاربر) برسد ادامه پیدا می‌کنند. توابع ارزیابی می‌توانند معیارهایی بر مبنای فاصله نظیر فاصله ماکسیمی یا اقلیدسی و یا طبقه‌بندی نظیر ماشین بردار پشتیبان (SVM) باشند. در این مقاله، فاصله ماکسیمی به صورت رابطه زیر استفاده گردید

$$d_m = ((x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i))^{1/2} \quad (3)$$

در رابطه بالا،  $x$  بردار ویژگی،  $\mu$  بردار میانگین و  $\Sigma$  ماتریس کوواریانس می‌باشد و بردارهای ویژگی با کمترین فاصله ماکسیمی به عنوان جواب‌های منتخب برگزیده می‌شوند. با افزایش تعداد جمعیت اولیه می‌توان موقعیت‌های بیشتری از فضای ویژگی را به قیمت افزایش زمان محاسبات بررسی نمود.

در مسأله انتخاب ویژگی با طول متغیر، این بار دیگر طول بردارهای ویژگی انتخاب شده با تعداد متغیرها در مسایل بهینه‌سازی توابع برابر نبوده و توانایی انتخاب زیرمجموعه‌های ویژگی از فضای اصلی با طول‌های

جدول ۲: عملکرد طبقه‌بندی نمونه‌ها با استفاده از SVM در روش رتبه‌بندی انفرادی در انتخاب ویژگی‌های شاخص بر اساس معیارهای تشخیصی استاندارد.

معیارهای تشخیصی (%)				NF	دقت	حساسیت	قطعیت	طبقه‌بند	آزمون آمارگان T
تشخیص	حساسیت	دقت	قطعیت						
۲۹,۵۰	۸۶,۸۴	۶۵,۹۳	۷	۷	۸۶,۸۴	۶۵,۹۳	۲۹,۵۰	طبقه‌بند	آزمون آمارگان T
۳۴,۱۴	۸۳,۷۲	۶۵,۶۵	۱۲	۱۲	۸۳,۷۲	۶۵,۶۵	۳۴,۱۴	ماشین	باچاتاریا
۳۵	۸۳,۰۳	۶۵,۵۲	۱۵	۱۵	۸۳,۰۳	۶۵,۵۲	۳۵	بردار	واگرایی
۳۷,۲۸	۸۴,۲۲	۶۷,۱۰	۹	۹	۸۴,۲۲	۶۷,۱۰	۳۷,۲۸	پشتیبان	منحنی مشخصه عملکرد گیرنده
۲۴,۲۱	۸۸,۸۹	۶۵,۳۱	۴	۴	۸۸,۸۹	۶۵,۳۱	۲۴,۲۱	(SVM)	ویلاکسون

جدول ۴: عملکرد طبقه‌بندی نمونه‌های سالم و بیمار پس از استخراج بردار ویژگی با روش SFS و فاصله باچاتاریا.

معیارهای تشخیصی (%)				NF	دقت	حساسیت	تشخیص	روش طبقه‌بندی
تشخیص	حساسیت	دقت	قطعیت					
۳۲,۱۴	۹۸,۳۶	۷۲,۳۹	۱۲	۱۲	۹۸,۳۶	۷۲,۳۹	۳۲,۱۴	SVM
۵۸,۰۷	۷۴,۱۸	۷۳,۶۹	۵۰	۵۰	۷۴,۱۸	۷۳,۶۹	۵۸,۰۷	LDA
۶۲,۸۵	۹۶,۷۲	۸۴,۳۷	۵۴	۵۴	۹۶,۷۲	۸۴,۳۷	۶۲,۸۵	QDA
۳۲,۱۴	۹۶,۷۲	۷۱,۶۱	۲۹	۲۹	۹۶,۷۲	۷۱,۶۱	۳۲,۱۴	KNN

روش ارزیابی متقابل ۱۰ نگهدار استخراج شده‌اند. جدول ۲ نتایج حاصل از طبقه‌بندی نمونه‌ها را با استفاده از طبقه‌بند SVM فهرست نموده است. نتایج نشان می‌دهد که روش‌های مختلف انتخاب ویژگی انفرادی به طور هم‌زمان منجر به معیارهای تشخیصی خوب نمی‌شوند. روش آمارگان T در قیاس با منحنی مشخصه حساسیت بالاتری داشته ولی دقت و قطعیت کمتری دارد.

با توجه به نتایج جدول ۲، ویژگی‌های منتخب آمارگان T از نظر تغییر نوع طبقه‌بند مورد بررسی قرار گرفت. عملکرد طبقه‌بندهای QDA، LDA و KNN بر روی ویژگی‌های منتخب با روش رتبه‌بندی انفرادی آمارگان T بر حسب طول بردار ویژگی منتخب و معیارهای تشخیصی استاندارد بررسی گردید. جدول ۳ نتایج حاصل از این بررسی را نشان می‌دهد که بهترین پاسخ با معیار حساسیت برای طبقه‌بند KNN در حالت  $K = 21$  حاصل شده است.

همان طور که از نتایج شبیه‌سازی مشاهده می‌شود عملکرد طبقه‌بندها با یکدیگر کاملاً متفاوت می‌باشد. رتبه‌بندی انفرادی ویژگی‌ها هرچند ساده است ولی برای مسایل پیچیده و ویژگی‌ها با همبستگی متقابل بالا اثربخش نیست.

در گام بعد به منظور بهبود میزان تفکیک دو گروه، با انتخاب ویژگی برداری، به روش جستجوی ترتیبی پیشرو (SFS) با فاصله باچاتاریا به عنوان معیاری جهت اندازه‌گیری جدایی‌پذیری کلاس‌های الگو جهت انتخاب ویژگی‌های برگزیده اقدام شد. عملکرد این روش بر اساس طبقه‌بندهای مختلف (SVM، LDA، QDA و KNN) بررسی گردید. نتایج حاصل بر اساس معیارهای تشخیصی در جدول ۴ آورده شده است. همچنین نتایج تشخیصی تعداد ویژگی‌های منتخب با روش SFS بر اساس معیار فاصله متفاوت بر حسب طبقه‌بند SVM در جدول ۵ آمده است.

نتایج شبیه‌سازی حاکی از آن است که کارایی طبقه‌بند در تفکیک افراد بهبود یافته است اما همچنان مشکل انتخاب بهینه تعداد متغیرها پابرجا می‌باشد چرا که مقدار بهینه  $d$  مناسب برای رسیدن به حداکثر تمایز بین گروه‌های تشخیصی معین نیست. حال با استفاده از الگوریتم تکاملی زنبور عسل به انتخاب مقدار  $d$  مناسب به طور شناور با بهترین جواب نهایی از انتخاب یک زیرمجموعه برداری از ویژگی‌های بهینه ممکن می‌پردازیم.

جدول ۳: عملکرد طبقه‌بندهای SVM، LDA، QDA و KNN پس از انتخاب ویژگی با روش رتبه‌بندی انفرادی آمارگان T.

معیارهای تشخیصی (%)				NF	دقت	حساسیت	تشخیص	روش طبقه‌بندی
تشخیص	حساسیت	دقت	قطعیت					
۲۹,۵۰	۸۶,۸۴	۶۵,۹۳	۷	۷	۸۶,۸۴	۶۵,۹۳	۲۹,۵۰	SVM
۵۷,۰۷	۶۴,۰۹	۶۱,۵۳	۲۹	۲۹	۶۴,۰۹	۶۱,۵۳	۵۷,۰۷	LDA
۳۶,۱۴	۷۶,۵۱	۶۱,۷۹	۳	۳	۷۶,۵۱	۶۱,۷۹	۳۶,۱۴	QDA
۲۰,۱۴	۸۸,۸۹	۶۳,۸۲	۱۷	۱۷	۸۸,۸۹	۶۳,۸۲	۲۰,۱۴	KNN

جدول ۵: عملکرد طبقه‌بندی نمونه‌ها با استفاده از SVM با معیار فاصله باچاتاریا و واگرایی در انتخاب بهترین گروه از ویژگی‌های شاخص بر اساس تعداد نشانگرهای حیاتی و معیارهای تشخیصی استاندارد.

معیارهای تشخیصی (%)				NF	دقت	حساسیت	تشخیص	روش طبقه‌بندی
تشخیص	حساسیت	دقت	قطعیت					
۵۱,۴۲	۹۳,۹۷	۷۱,۶۱	۲۰	۲۰	۹۳,۹۷	۷۱,۶۱	۵۱,۴۲	طبقه‌بند ماشین باچاتاریا
۳۳,۵۷	۸۹,۵۰	۶۷,۱۸	۶	۶	۸۹,۵۰	۶۷,۱۸	۳۳,۵۷	بردار پشتیبان (SVM) واگرایی

بدین منظور، نیمی از داده‌های موجود در هر کلاس جهت ارزیابی و مابقی برای آموزش استفاده گردید. لازم به ذکر است جهت جلوگیری از مسئله فوق یادگیری، فقط یک مجموعه آموزش برای انتخاب ویژگی استفاده شد. پارامترهای تشخیص صحیح یا دقت، حساسیت و قطعیت به عنوان معیار سنجش عملکرد طبقه‌بندی استفاده شده است. در هر مورد دقت به صورت نسبت تشخیص‌های صحیح به تعداد کل نمونه‌ها، حساسیت به صورت نسبت نمونه‌های بیمار که به درستی تشخیص داده شده‌اند به کل نمونه‌های بیمار و میزان قطعیت نیز به صورت نسبت تعداد نمونه‌های سالمی که به درستی سالم تشخیص داده شده‌اند، محاسبه شده است.

### ۳-۱ نتایج حاصل از انتخاب ویژگی با آزمون‌های آماری

در گام اول، انتخاب ویژگی بر مبنای معیارهای رتبه‌بندی انفرادی ویژگی‌ها مبتنی بر آزمون آماری (ttest و wilcoxon)، منحنی مشخصه عملکرد گیرنده (ROC) و ارزیابی اطلاعات (Bhattacharyya) و entropy صورت گرفته و ۱۰۰ عدد از بهترین ویژگی‌ها برای طبقه‌بند SVM انتخاب شده است. سپس ترکیب‌های مختلف از بردارهای ویژگی در بین این ۱۰۰ ویژگی منتخب مبتنی بر طبقه‌بند ماشین بردار پشتیبان با بُعد یک تا صد انتخاب شده و معیارهای تشخیصی برای این ترکیب‌ها محاسبه شده است. پس از آن، بُعد زیربهینه با محاسبه بیشینه دقت تشخیص برای انتخاب بهترین بردار ویژگی از بین ۱۰۰ ویژگی حساب گردید. این تعداد ویژگی که با علامت اختصاری NF در جدول ۲ نشان داده شده است برای یک مجموعه یادگیری که به صورت تصادفی انتخاب شده است محاسبه گردیده و در نهایت، نتایج کلی با متوسط‌گیری به



جدول ۶: ماتریس درهم‌ریختگی اعمال روش پیشنهادی بر روی تصاویر رقابت بین‌المللی ۲۰۰-ADHD.

نتیجه اعمال روش پیشنهادی بر روی تصاویر	حالت طبقه‌بندی	
	تشخیص به عنوان	نوع تصویر
۲۳۴	سالم	سالم
۱۰	بیمار	سالم
۱۱۸	بیمار	بیمار
۲۲	سالم	بیمار

جدول ۷: مقایسه میانگین عملکرد روش پیشنهادی با سایر روش‌ها بر روی تصاویر رقابت بین‌المللی ۲۰۰-ADHD.

تفاوت روش پیشنهادی و بهترین میانگین سایر روش‌ها (%)	میانگین روش پیشنهادی (%)	میانگین سایر روش‌ها (%)	معیارهای تشخیصی (%)
+۳۷,۸۷	۹۰,۸۵	۵۲,۹۸	دقت
+۲۳,۱۹	۹۵,۹۰	۷۲,۷۱	قطعیت
+۴۵,۲۴	۸۴,۲۸	۳۹,۰۴	حساسیت

مقدار قطعیت ۹۴٪، بهترین مقدار در میان سایر روش‌ها می‌باشد، این روش به مقدار بالاتری دست یافت و در حالی که بالاترین نرخ تشخیص افراد بیمار در میان روش‌های دیگر ۷۲/۷۳٪ بوده است، روش پیشنهادی توانسته به مقدار ۸۴/۲۸٪ دست یابد.

#### ۴- نتیجه‌گیری

در این مقاله به منظور تشخیص بهتر بیماری ADHD، با استفاده از مجموعه داده حاصل از تصویرنگاری تشدید مغناطیسی در حالت استراحت مربوط به یک رقابت بین‌المللی (ADHD-۲۰۰) در سال ۲۰۱۱ میلادی و اطلس AAL، از مقادیر همبستگی بین مناطق ۱۱۵ گانه مغز در این اطلس استفاده شده است. با محاسبه همبستگی دوه‌دوی این مناطق، تعداد ۶۶۷۰ ضریب همبستگی وجود خواهد داشت که این تعداد بسیار بیشتر از تعداد کل تصاویر آموزشی می‌باشد. در نتیجه باید تعداد این ویژگی‌ها کاهش می‌یافت. با توجه به این که تا کنون روش مشخص و مؤثری برای این کار گزارش نشده و هر کدام از این ۶۶۷۰ ویژگی به خودی خود مهم می‌باشند، از ترکیب دقت و سرعت الگوریتم‌های تکاملی برای تفکیک داده‌های آزمایش در این تحقیق استفاده شده است.

الگوریتم جدیدی به نام الگوریتم زنبور عسل بهبودیافته ارائه شد. الگوریتم پیشنهادی دارای این تفاوت عمده است که این بار دیگر طول بردارهای ویژگی انتخاب‌شده با تعداد متغیرها در مسایل بهینه‌سازی توابع برابر نبوده و توانایی انتخاب زیرمجموعه‌های ویژگی را از فضای ویژگی اصلی با طول‌های متفاوت داراست.

نتایج حکایت از کارایی به مراتب بالاتر الگوریتم زنبور عسل با طول متغیر نسبت به سایر روش‌ها دارد. بررسی دقت طبقه‌بندی کلی نشان می‌دهد روش پیشنهادی عملکرد بسیار بهتری داشته است در حالی که بالاترین مقدار به دست آمده در رقابت ۲۰۰-ADHD مربوط به دانشگاه آلبرتا و با مقدار ۶۲/۵۲٪ و یا مقدار ۷۶/۶۱٪ توسط آقای یوسفی و همکاران با ۲۶ ویژگی بوده است، روش پیشنهادی توانسته با ۲۵ ویژگی به مقدار دقت طبقه‌بندی کلی ۸۵/۳۲٪ دست یابد. البته با توجه به همبستگی بالای بین ویژگی‌ها، با افزایش طول بردار ویژگی دقت طبقه‌بندی کلی بهبود قابل ملاحظه‌ای پیدا می‌کند. به این صورت که با انتخاب ویژگی با طول ۳۵ به ۹۱/۶۶٪ و یا با طول ۴۵ تا به ۹۵/۵۷٪ رسیده است.

همچنین روش پیشنهادی در تشخیص افراد سالم به عنوان فرد سالم و در تشخیص افراد بیمار به عنوان بیمار نیز بسیار موفق عمل کرده است. بر این اساس در تشخیص افراد سالم به عنوان فرد سالم، در حالی که به طور میانگین سایر روش‌ها توانسته بودند به مقدار تشخیص ۷۲/۷۱٪ دست یابند، این روش توانست به مقدار ۹۵/۹۰٪ دست یابد. همچنین توانایی این روش در تشخیص افراد بیمار به عنوان بیمار، بسیار بهتر از عملکرد تمامی روش‌های موجود است. در حالی که سایر روش‌ها توانسته‌اند به طور

#### ۳-۲ نتایج حاصل از انتخاب ویژگی با استفاده از الگوریتم زنبور عسل بهبودیافته

الگوریتم زنبور عسل پیشنهادی به انتخاب ویژگی‌ها با طول متغیر می‌پردازد تا بتواند بر مشکل انتخاب ویژگی در الگوریتم‌هایی که در آن طول بردار ویژگی ثابت در نظر گرفته می‌شود غلبه کند. پارامترهای کنترلی به صورت  $\max \text{limit} = 50$  و  $\text{number of iteration} = 200$  تنظیم گردید. تا زمانی که جواب‌های مسأله در هر گام شایستگی بیشتری از مقدار پارامتر  $\max \text{limit}$  را کسب نکرده باشند این پاسخ‌ها به طور کلی رها شده و جواب اولیه‌ای را به صورت تصادفی پدید می‌آورد و مراحل قبلی را عیناً بر روی آن پیاده‌سازی می‌کند. این مراحل تا زمانی که الگوریتم به شرط خاتمه که یا برآورده کردن خواسته مسأله است یا این که به مقدار پارامتر  $\text{number of iteration}$  که توسط کاربر از پیش مشخص گردیده است برسد ادامه پیدا می‌کند. برای تابع ارزیابی از معیار فاصله ماهالانوبیس استفاده شده است.

کارایی الگوریتم از لحاظ مقدار تابع هدف در درجه اول و زمان پردازش در درجه دوم مورد بررسی قرار می‌گیرد. نتایج حاکی از کارایی به مراتب بالاتر الگوریتم زنبور عسل با طول متغیر نسبت به سایر روش‌ها است. بنابراین روش پیشنهادی توانسته با ۲۵ ویژگی به مقدار دقت طبقه‌بندی کلی ۸۵/۳۲٪ دست یابد. جدول ۶ ماتریس درهم‌ریختگی روش پیشنهادی را براساس ۲۵ ویژگی منتخب جهت تفکیک افراد سالم از بیمار نشان می‌دهد. با توجه به همبستگی بین ویژگی‌ها با افزایش طول بردار ویژگی دقت طبقه‌بندی کلی بهبود قابل ملاحظه‌ای پیدا می‌کند به این صورت که با انتخاب ویژگی با طول ۳۵ به ۹۱/۶۶٪ و یا با طول ۴۵ به ۹۵/۵۷٪ رسیده است. همچنین روش پیشنهادی در تشخیص افراد سالم به عنوان فرد سالم و در تشخیص افراد بیمار به عنوان بیمار بسیار موفق عمل کرده است. بر این اساس در تشخیص افراد سالم به عنوان فرد سالم، این روش توانست به مقدار قطعیت ۹۵/۹۰٪ دست یابد. همچنین توانایی این روش در تشخیص افراد بیمار به عنوان بیمار، بسیار بهتر از تمامی روش‌های موجود عمل کرده است. روش پیشنهادی توانسته به میزان حساسیت ۸۴/۲۸٪ دست یابد.

نتایج روش پیشنهادی در مقایسه با میانگین سایر روش‌ها که در رقابت شرکت داشته‌اند در جدول ۷ آورده شده است. این نتایج نشان می‌دهند که روش پیشنهادی بسیار بهتر از سایر روش‌ها عمل کرده است. میانگین میزان دقت تشخیصی در روش پیشنهادی برابر ۹۰/۸۵٪ به دست آمده و این در حالی است که بالاترین میزان دقت در بین شرکت‌کنندگان این رقابت، برابر ۶۲/۵۲٪ توسط تیمی از دانشگاه آلبرتا بوده است. همچنین با مقایسه معیارهای تشخیصی حساسیت و قطعیت همان طور که در جدول ۷ مشاهده می‌شود، روش پیشنهادی توانسته به مقدار قطعیت ۹۵/۹۰٪ دست یابد که با توجه به این که روش مربوط به دانشگاه جان‌هاپکینز با

the MNI MRI single-subject brain," *Neuroimage*, vol. 15, no. 1, pp. 273-289, Jan. 2002.

- [13] W. Cheng, X. Ji, J. Zhang, and J. Feng, "Individual classification of ADHD patients by integrating multiscale neuroimaging markers and advanced pattern recognition techniques," *Frontiers in System Neuroimaging*, vol. 6, Article 58, 6 Aug. 2012.
- [14] NITRC, *Neuro Bureau: Athena Pipeline*, Available at [http://www.nitrc.org/plugins/mwiki/index.php/neurobureau:AthenaPipeline#Regional\\_Homogeneity](http://www.nitrc.org/plugins/mwiki/index.php/neurobureau:AthenaPipeline#Regional_Homogeneity). 28ReHo.29
- [15] I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *J. of Machine Learning Research*, vol. 3, no. 1, pp. 1157-1182, 3 Mar. 2003.
- [16] S. Theodoridis, A. Pikrakis, K. Koutroumbas, and D. Cavouras, *Introduction to Pattern Recognition: A MATLAB Approach*, Academic Press, 2010.
- [17] D. Karaboga and B. Akay, "A comparative study of Artificial Bee Colony algorithm," *Applied Mathematics and Computation*, vol. 214, no. 1, pp. 108-132, 1 Aug. 2009.
- [18] J. Huang, Y. Cai, and X. Xu, "A hybrid genetic algorithm for feature selection wrapper based on mutual information," *Pattern Recognition Letters*, vol. 28, no. 13, pp. 1825-1844, 1 Oct. 2007.
- [19] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proc. IEEE Int. Conf. on Neural Networks*, vol. 4, pp. 1942-1948, Perth, Australia, 27 Nov.- 1 Dec. 1995.
- [20] B. O. Aljila, L. C. Peng, A. T. Khader, and M. A. Al-Betar, "Intelligent water drops algorithm for rough set feature selection," in *the Proc. of the 5th Asian Conf. on Intelligent Information and Database Systems*, pp. 356-36, Kuala Lumpur, Malaysia, 18-20 Mar. 2013.

**مریم رمضانیان کشتلی** تحصیلات مهندسی کامپیوتر گرایش سخت‌افزار خود را در مقطع کارشناسی در سال ۱۳۹۱ و در مقطع کارشناسی ارشد رشته مهندسی پزشکی گرایش بیوالکترونیک در سال ۱۳۹۴ از دانشگاه صنعتی نوشیروانی بابل به پایان رسانده است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: تشخیص الگو، الگوریتم‌های بهینه‌سازی، پردازش سیگنال و تصویر، شبکه‌های عصبی و کاربردهای آن.

**حسین منتظری کردی** مدرک کارشناسی مهندسی برق گرایش الکترونیک خود را در سال ۱۳۷۸ از دانشگاه مازندران، و مدارک کارشناسی ارشد و دکتری مهندسی پزشکی گرایش بیوالکترونیک خود را در سال‌های ۱۳۸۲ و ۱۳۸۸ به ترتیب از دانشگاه صنعتی شریف، و تربیت مدرس دریافت نمود. نام‌برده به‌عنوان عضو هیأت علمی از سال ۱۳۸۹ تاکنون در دانشکده مهندسی برق و کامپیوتر دانشگاه صنعتی نوشیروانی بابل مشغول به کار می‌باشد. زمینه‌های علمی مورد علاقه ایشان در حوزه تشخیص الگو، پردازش سیگنال و تصویر، مدلسازی سیستم‌های بیولوژیکی، و ابزار دقیق پزشکی می‌باشد.

میانگین به میزان حساسیت ۳۹/۰۴٪ دست یابند و بالاترین نرخ تشخیص افراد بیمار در میان آنها ۷۲/۷۳٪ بوده است، روش پیشنهادی توانسته به مقدار ۸۴/۲۸٪ دست یابد. از مجموع این آمار و ارقام می‌توان نتیجه گرفت روش پیشنهادی بسیار موفق‌تر از سایر روش‌ها عمل کرده است.

## مراجع

- [1] T. Banaschewski, et al., "Attention-deficit/hyperactivity disorder," *Deutsches Ärzteblatt International*, vol. 114, no. 9, pp. 149-159, 3 Mar. 2017.
- [2] -, *ADHD in Children*, Available at: <http://www.adhd.com/index.html>
- [۳] م. یوسفی، ع. ا. ابراهیم‌زاده، ع. خزائی و ع. باباجانی، "آنالیز داده‌های fMRI حالت استراحت با استفاده از الگوریتم PSO به منظور تشخیص ADHD"، *مجله علمی-پژوهشی رایانش نرم و فناوری اطلاعات*، جلد ۱، شماره ۳، صص. ۵۳-۶۶، پاییز ۱۳۹۱.
- [4] S. Clare, *Functional Magnetic Resonance Image: Methods and Applications*, PhD Thesis, University of Nottingham, England, 1997.
- [5] C. Z. Zhu, et al., "Fisher discriminative analysis of resting-state brain function for attention-deficit/hyperactivity disorder," *Neuroimage*, vol. 40, no. 1, pp. 110-120, 1 Mar. 2008.
- [6] W. Cheng, X. Ji, J. Zhang, and J. Feng, "Individual classification of ADHD patients by integrating multiscale neuroimaging markers and advanced pattern recognition techniques," *Frontiers in Systems Neuroscience*, vol. 6, Article 58, 6 Aug. 2012.
- [7] D. Tomasi and N. D. Volkow, "Abnormal functional connectivity in children with attention-deficit/hyperactivity disorder," *Biological Psychiatry*, vol. 71, no. 5, pp. 443-450, 1 Mar. 2012.
- [8] A. Eloyan, et al., "Automated diagnoses of attention-deficit/hyperactivity disorder using magnetic resonance imaging," *Frontiers in Systems Neuroscience*, vol. 6, Article 61, 30 Aug. 2012.
- [9] D. Dai, J. Hua, and H. He, "Classification of ADHD children through multimodal magnetic resonance imaging," *Frontiers in Systems Neuroscience*, vol. 6, Article 63, 3 Sept. 2012.
- [10] Q. Cao, Y. Zang, L. Sun, M. Sui, X. Long, Q. Zou, and Y. Wang, "Abnormal neural activity in children with Attention-Deficit Hyperactivity Disorder: a resting-state functional magnetic resonance imaging study," *Neuroreport*, vol. 17, no. 10, pp. 1033-1036, 17 Jul. 2006.
- [11] M. P. Millan, D. Fair, M. Mennes, and S. H. Mostofsky, "The ADHD-200 Consortium: a model to advance the translational potential of neuroimaging in clinical neuroscience," *Frontiers in System Neuroscience*, vol. 6, Article 62, 6 Sept. 2012.
- [12] N. Tzourlo-Mazoyer, et al., "Automated anatomical labeling of activations in SPM using a macroscopic anatomical parcellation of