

Accuracy Improvement of Mood Disorders Prediction using a Combination of Data Mining and Meta-Heuristic Algorithms

Fariborzi Mana¹, Zeinalnezhad Masoomeh^{2*}, Saghaei Abbas³

• Received: 25 Aug 2022

• Accepted: 20 Nov 2022

Introduction: Since the delay or mistake in the diagnosis of mood disorders due to the similarity of their symptoms hinders effective treatment, this study aimed to accurately diagnose mood disorders including psychosis, autism, personality disorder, bipolar, depression, and schizophrenia, through modeling and analyzing patients' data.

Method: Data collected in this applied developmental research included 996 records with 130 features obtained by interviewing and completing questionnaires in a mental hospital in the city of Sari, Iran in 2021. After preprocessing, the number of features was reduced to 91, and then through Principal Component Analysis (PCA) reduced to 35 factors. Modeling was done in Python software with K-Nearest Neighbor (KNN), Naive Bayes (NB), Decision Tree (DT), Random Forest (RF), Logistic Regression (LR), and Support Vector Machine (SVM) algorithms. The models were evaluated to select algorithms with higher accuracy. Particle Swarm Optimization (PSO) and Genetic Algorithm (GA) were applied to determine the optimal parameters of the selected algorithms.

Results: Among the machine learning algorithms, random forest with 91% accuracy and support vector machine with 90% accuracy showed better performance. The genetic algorithms did not make any notable increase in prediction accuracy. Whereas considering $N=30$, $T=150$, $W=0.9$, $c1=2$, and $c2=2$ in the particle swarm optimization algorithm increased the prediction accuracy up to 3.3 %.

Conclusion: With less classification error compared to similar studies, the PSO-SVM model designed in this study can be used in patient data monitoring with acceptable accuracy and can be used in intelligent systems in psychiatric centers.

Keywords: Mood Disorder, Machine Learning, Meta-Heuristic Algorithms, Data Mining, Prediction

• **Citation:** Fariborzi M, Zeinalnezhad M, Saghaei A. Accuracy Improvement of Mood Disorders Prediction using a Combination of Data Mining and Meta-Heuristic Algorithms. *Journal of Health and Biomedical Informatics* 2022; 9(3): 106-119. doi: 10.34172/jhbmi.2022.01. [In Persian]

1. M.Sc. in Industrial Engineering, Department of Industrial Engineering, Faculty of Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

2. Ph.D. in Industrial Engineering, Assistant Professor, Department of Industrial Engineering, Faculty of Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran

3. Ph.D. in Industrial Engineering, Professor, Department of Industrial Engineering, Faculty of Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

*Corresponding Author: Masoomeh Zeinalnezhad

Address: Department of Industrial Engineering, West Tehran Branch, Islamic Azad University, Shahid Hasan Azari St., Hemmat Bridge, Ashrafi Esfahani Hwy, Tehran, Iran

•Tel: 021-44220677

•Email: zeinalnezhad.m@wtiau.ac.ir

بهبود دقت پیش‌بینی اختلالات خلقی با استفاده از ترکیب الگوریتم‌های داده‌کاوی و فراابتکاری

مانا فری برزی^۱، معصومه زینال نژاد^{۲*}، عباس سقایی^۳

• دریافت مقاله: ۱۴۰۱/۶/۳ • پذیرش مقاله: ۱۴۰۱/۸/۲۹ •

مقدمه: از آنجا که تأخیر یا اشتباه در تشخیص اختلالات خلقی به دلیل تشابه علائم، مانع درمان مؤثر می‌شود، هدف تحقیق حاضر، تشخیص دقیق اختلالات خلقی، شامل روان‌پریشی، اوتیسم، اختلال شخصیت، دوقطبی، افسردگی و اسکیزوفرنی، از طریق مدل‌سازی و تحلیل داده‌های بیماران است.

روش: داده‌های جمع‌آوری شده در این پژوهش کاربردی-توسعه‌ای دربردارنده ۹۹۶ رکورد با ۱۳۰ ویژگی بود که با مصاحبه و تکمیل پرسشنامه‌ها در یک بیمارستان روان‌پزشکی در شهر ساری، ایران در سال ۱۴۰۰ گردآوری شد. پس از پیش‌پردازش داده‌ها، تعداد ویژگی‌ها با تحلیل همبستگی به ۹۱ و سپس با تحلیل مؤلفه‌های اصلی (PCA) به ۳۵ فاکتور کاهش یافت. مدل‌سازی داده‌ها در نرم‌افزار پایتون با الگوریتم‌های K نزدیک‌ترین همسایه (KNN)، نایو بیز (NB)، درخت تصمیم (DT)، جنگل تصادفی (RF)، رگرسیون لجستیک (LR) و ماشین بردار پشتیبان (SVM) صورت گرفت. عملکرد مدل‌ها ارزیابی گردید و پارامترهای الگوریتم‌های با دقت بالاتر توسط الگوریتم‌های فراابتکاری بهینه‌سازی ازدحام ذرات (PSO) و ژنتیک (GA) تخمین زده شد.

نتایج: از بین الگوریتم‌های یادگیری ماشین، دو الگوریتم RF با دقت ۹۱ و SVM با دقت ۹۰ درصد عملکرد بهتری داشتند. GA افزایش دقت قابل‌ملاحظه‌ای ایجاد نکرد، اما در نظر گرفتن مقادیر ۳۰، ۱۵۰، ۰/۹ و ۲ به ترتیب به عنوان تعداد ذرات، تعداد تکرار الگوریتم، ضریب اینرسی، ضریب شخصی و ضریب اجتماعی در الگوریتم PSO دقت پیش‌بینی را تا ۳/۳ درصد بهبود بخشید.

نتیجه‌گیری: با خطای طبقه‌بندی کمتر نسبت به پژوهش‌های مشابه، مدل PSO-SVM طراحی شده در این پژوهش با دقت قابل قبولی می‌تواند در پایش داده‌های بیماران به کار گرفته شده و در سامانه‌های هوشمند مراکز روان‌پزشکی مورد استفاده قرار گیرد.

کلیدواژه‌ها: اختلال روانی، یادگیری ماشین، الگوریتم‌های فرا ابتکاری، داده‌کاوی، پیش‌بینی

ارجاع: فری برزی مانا، زینال نژاد معصومه، سقایی عباس. بهبود دقت پیش‌بینی اختلالات خلقی با استفاده از ترکیب الگوریتم‌های داده‌کاوی و فراابتکاری. مجله انفورماتیک سلامت و

زیست پزشکی ۱۴۰۱؛ ۹(۳): ۱۰۶-۱۱۹. doi: 10.34172/jhbmi.2022.01

۱. کارشناس ارشد مهندسی صنایع-سیستم‌های سلامت، گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲. دکترای مهندسی صنایع، استادیار، گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران

۳. دکترای مهندسی صنایع، استاد، گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

* نویسنده مسئول: معصومه زینال نژاد

آدرس: تهران، بلوار اشرفی اصفهانی، خیابان قموشی، بلوار عربشاهی، خیابان شهید حسن آذری، دانشکده فنی و مهندسی دانشگاه آزاد اسلامی واحد تهران غرب، گروه مهندسی صنایع

• Email: m.zeinalnezhad@gmail.com

• شماره تماس: ۰۲۱-۴۴۲۲۰۶۷۷

مقدمه

امروزه نشاط اجتماعی یکی از مهم‌ترین نیازهای جامعه است چراکه شهروندان به‌ویژه ساکنان کلان‌شهرها، فرصت کمتری برای اندیشیدن به خود و نیازهایشان دارند و به‌شدت مستعد اختلالات خلقی هستند [۱]. افراد مبتلا به بیماری‌های روانی در سراسر جهان تا حد زیادی نادیده گرفته می‌شوند [۲]. اختلالاتی مانند افسردگی، اسکیزوفرنی و دوقطبی به ترتیب ۱/۸۴ درصد، ۰/۶۰ درصد، ۰/۳۳ درصد از کل سال‌های زندگی با ناتوانی تعدیل‌شده را تشکیل می‌دهند [۳]. مشکلات سلامت روان می‌تواند به پیامدهای جدی مانند افسردگی، خودزنی به‌خصوص برای دانش‌آموزانی که از نظر جسمی و روحی بالغ نیستند، منجر شود [۴]. افسردگی، در صورت عدم تشخیص و درمان به‌موقع، می‌تواند منجر به خودکشی شده [۵، ۶]. یا تأثیر منفی بر روند بیماری‌های جسمی مانند سکنه مغزی، سرطان داشته و هزینه‌های پزشکی را افزایش دهد [۷]. اختلال دوقطبی یک بیماری مزمن شایع و عودکننده است که تأثیر مستقیمی بر سلامت بیمار دارد [۸] و در دو سوم بیماران قابل درمان نیست [۹]. خلُق بر طبق تعریف عبارت است از احساس هیجانی نافذی که درک و نگرش فرد نسبت به خود، دیگران و در کل نسبت به محیط اطراف را عمیقاً تحت تأثیر قرار می‌دهد [۱۰]. خلُق ممکن است طبیعی و یا غیرطبیعی باشد. یک فرد عادی طیف وسیعی از خلُق‌ها را تجربه می‌کند و به همان نسبت مجموعه‌ای از تجلیات عاطفی نیز دارد. این فرد قادر به کنترل اخلاق و عواطف خود است. اختلالات خلُقی حالات بالینی هستند که با اختلال خلُق، فقدان احساس کنترل بر خلُق و تجربه ذهنی ناراحتی شدید همراه است. بر اساس تعریف سازمان بهداشت جهانی، اختلالات خلُقی، مانند اختلال افسردگی عمده و اختلال دوقطبی، دربرگیرنده اختلالات خلُقی مکرر و مزمن است [۳]؛ بدین علت بیماران مبتلا به اختلالات خلُقی از فشار شدید، اختلال در سطح عملکردی و افزایش خطر خودکشی رنج می‌برند [۱۱]. تأخیر در تشخیص و در بیشتر موارد تشخیص اشتباه اختلالات خلقی به دلیل تشابه علائم آن‌ها مانع از درمان مؤثر بیماران می‌شود. پیش‌بینی شروع و سیر اختلالات خلقی و اضطرابی با وجود اهمیت بالا بسیار دشوار است [۱۲]. به‌عنوان نمونه، اختلال دوقطبی از اختلال افسردگی عمده را با دقت بالا نمی‌توان تشخیص داد [۱۳]. تشخیص برای بیمارانی که بیش از یک نوع اختلال روانی دارند، سخت‌تر است [۱۴]. در صورت تشخیص درست بیماری، روان‌درمانی شناختی-رفتاری در کنار درمان‌های معمول، در کاهش علائم و نشانه‌های اختلال خلقی در بیماران

مؤثر است و استفاده از رویکرد تیمی مبتنی بر همکاری روان‌شناس و روان‌پزشک می‌تواند نتایج درمانی بهتری داشته باشد [۱۵]. همچنین، آموزش‌های مهارت اجتماعی می‌تواند با اصلاح روابط بین فردی بیماران، زمینه را برای کاهش تعاملات ناکارآمد و در نتیجه کاهش عواطف منفی و سازگاری اجتماعی افراد فراهم کند [۱۶].

با توجه به پیچیدگی تشخیص درست نوع بیماری افراد بیمار، به ابزارهای تشخیصی آسان‌تر و دقیق‌تری نیاز است [۱۷]. در این خصوص، استفاده از علم داده‌کاوی در تحقیقات مهندسی سلامت و پایش اطلاعات بیماران رو به افزایش است [۱۸]. یادگیری ماشین (Machin Learning) به‌عنوان روشی مناسب برای تجزیه و تحلیل داده‌های بزرگ شناخته شده که توسط آلن تورینگ (Allan Turing) و آرتور ساموئل (Arthur Samuel) در دهه ۱۹۵۰ ابداع گردید و از اواخر قرن بیستم تاکنون در زمینه‌های مختلف از جمله حوزه پزشکی کاربرد گسترده داشته است [۱۹]. همچنین، هوش مصنوعی به دلیل قابلیت بالا در خودکارسازی و کار با داده‌های انبوه و قابلیت استنتاج قوی، کاربرد فراوانی در حیطه تشخیص اختلالات روانی داشته است [۲۰]. با گسترش شبکه‌های اجتماعی و ظهور کلان داده‌ها، داده‌های زیادی درباره بیماران روانی در دسترس متخصصین روان‌شناسی است. این داده‌ها منبعی غنی برای یاری‌رسانی به روان‌شناسان در تشخیص اختلالات روانی است [۲۱]. داده‌ها را از منابع مختلفی همچون دستگاه‌های پوشیدنی و گوشی‌های هوشمند می‌توان جمع‌آوری کرد [۲۲، ۲۳]. تحلیل و سازمان‌دهی این داده‌ها به‌صورت دستی دشوار است درحالی‌که هوش مصنوعی می‌تواند با پایش داده‌ها و استنتاج و پیش‌بینی به متخصصین روان‌شناسی در تشخیص بیماری‌های روانی بر اساس تصاویر، صوت و یا متن یاری رساند [۲۴]. در میان روش‌های هوش مصنوعی، دو رویکرد یادگیری ماشین و یادگیری عمیق نتایج خوبی در ارزیابی و تشخیص اختلالات روانی از خود نشان داده‌اند [۲۵]. یادگیری ماشین می‌تواند به‌عنوان یک بخش مهم و اساسی در تجزیه و تحلیل داده‌های بزرگ، در نظر گرفته شود [۱۷] و در حل مسائل مراقبت‌های بهداشتی مانند تشخیص زودرس بیماری، نظارت بر بیمار در زمان واقعی، مراقبت از بیمار و تقویت درمان نقش داشته باشد [۲۶]. در این راستا، Liu و همکاران [۱۴]، در تحقیقی با استفاده از مدل‌های یادگیری عمیق به بررسی تشخیص ۸ بیماری روانی شاخص شامل بیش‌فعالی، افسردگی، اضطراب، اوتیسم، ناتوانی‌های فکری، اختلال گفتار/زبان، تأخیر در تحولات و

اختلال سرپیچی مخالف در بین بیمارانی از اقلیت قومی آفریقایی- آمریکایی پرداختند. داده‌های گردآوری شده شامل ۴۱۷۹ رکورد بود که در آن میان، ۱۳۸۴ بیمار با تشخیص حداقل یک اختلال روانی وجود داشتند. دقت مدل طراحی شده ۶۵ درصد تخمین زده شد. de Siqueira Rotenberg و همکاران [۲۷] با هدف استفاده از رویکردهای یادگیری ماشین به‌عنوان یک پیش‌بینی‌کننده احتمالی در عود افسردگی در دوقطبی مطالعه‌ای انجام دادند که در آن الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی، بیزین ساده و پرسپترون چندلایه به مجموعه داده‌ها اعمال شد. در هر دو پژوهش الگوریتم جنگل تصادفی میانگین عملکرد بالاتری را به دست آورد. Bayes و همکاران [۲۸] یک رویکرد یادگیری ماشین را برای تشخیص اختلال دوقطبی (Bipolar Disorder) از اختلال شخصیت مرزی (Borderline Personality Disorder) ارائه کردند. دقت طبقه‌بندی مدل‌های یادگیری ماشین بین ۸۴/۱ درصد تا ۸۷/۸ درصد برای اختلال دوقطبی و ۵۰ تا ۵۷/۷ درصد برای اختلال شخصیت مرزی و با دقت کلی ۷۳/۱ درصد الی ۷۳/۹ درصد بود. با توجه به تأثیر مستقیم اختلال دوقطبی بر رفاه بیمار، Liu و همکاران [۸]، یک مطالعه گذشته‌نگر برای ارزیابی افزایش عملکرد پرسشنامه‌های غربالگری اختلال دوقطبی نسبت به Mood Disorder Questionnaire (پرسشنامه اختلال خلقی) از یک رویکرد یادگیری ماشینی طراحی شده برای ارزیابی مجموعه‌ای از بیماری‌های سلامت روان استفاده کرده‌اند. در مرکز سلامت روانی در غرب کانادا شرکت‌کنندگان ($n=955$): ۵۶/۴ درصد زن؛ میانگین سنی ۳۵/۴ و ۱۸/۷ درصد دوقطبی) پرسشنامه را تکمیل کردند و برای دقت تشخیصی تحت یک مصاحبه بالینی با روان‌پزشک قرار گرفتند. با استفاده از امتیازدهی ترکیبی، دقت ۸۰/۶ درصد، با حساسیت ۷۳/۷ درصد و ویژگی ۸۷/۵ درصد بود. در مقایسه با روش امتیازدهی اصلی Mood Disorder Questionnaire، مدل ترکیبی دقت را تا ۶/۹ درصد، حساسیت را تا ۱۴/۵ درصد بهبود بخشید و درعین حال ویژگی را حفظ کرد.

van Eeden و همکاران [۱۲] روش‌های یادگیری ماشین احتمالی اولیه و خودکار (Auto-sklearn) را مقایسه کردند. داده‌ها از مطالعه افسردگی و اضطراب در هلند به دست آمده بود. رگرسیون لجستیک چندجمله‌ای، طبقه‌بندی‌کننده ساده بیز و Auto-sklearn تشخیص‌های افسردگی و اضطراب را در یک پیگیری ۲، ۴، ۶ و ۹ ساله پیش‌بینی کردند که به‌عنوان متغیرهای


باینری یا طبقه‌بندی عملیاتی شدند. مجموعه‌های پیش‌بینی‌کننده شامل داده‌های جمعیت‌شناختی و خود گزارشی بود که می‌توان آن‌ها را به راحتی در عمل بالینی در دو نقطه زمانی اولیه (پایه و پیگیری ۱ ساله) جمع‌آوری کرد. این سه روش به‌طور مشابه در پیش‌بینی وضعیت سلامت روانی با پیش‌بینی‌های صحیح تا ۷۹ درصد موفق بودند. با این حال، Auto-sklearn هنگام ارزیابی مجموعه داده‌های پیچیده‌تر با امتیازات ویژگی‌ها برتر بود.

Nguyen و همکاران [۲۹] در پژوهشی بیماران اختلالات سلامت روان را به دو گروه اسکیزوفرنی و اختلالات خلقی (دو قطبی و تک قطبی) تقسیم نمودند. آن‌ها از دو الگوریتم‌های یادگیری عمیق استفاده نمودند. داده‌ها با استفاده از دستگاه پوشیدنی جمع‌آوری شدند. دقت به دست آمده در پژوهش ۸۶/۰ و ۷۹/۰ بود.

تمرکز در حیطه فقط یک بیماری روانی در بیشتر پژوهش‌ها و یا عدم استفاده از داده‌های کافی، همچنین دقت پایین تشخیص با استفاده از الگوریتم‌های محدود و یا عدم به‌کارگیری روش‌های دیگر برای بهبود دقت کار ضعف شناخته‌شده در بررسی تحقیقات پیشین هستند. در پژوهش حاضر تلاش شده است تا با بررسی انواع اختلالات خلقی و شناسایی تمامی ویژگی‌های مؤثر و استفاده همزمان از الگوریتم‌های یادگیری ماشین و فرا ابتکاری مدلی طراحی شود که بتواند شش نوع از اختلالات خلقی شامل روان‌پریشی، اوتیسم، اختلال شخصیت، دوقطبی، افسردگی و اسکیزوفرنی را از یکدیگر تمایز داده و با توجه به علائم، آن‌ها را با دقت قابل قبولی پیش‌بینی نماید.

روش

مجموعه داده مورد تحلیل در این پژوهش کاربردی-توسعه‌ای دربردارنده ۹۹۶ رکورد با ۱۳۰ ویژگی بوده است که با استفاده از پرسشنامه استاندارد موجود، از طریق مصاحبه با بیماران یک بیمارستان روان‌پزشکی در شهر ساری در سال ۱۴۰۰ گردآوری شد. این مجموعه داده شامل ۱۷۵ رکورد بیماران دوقطبی، ۱۶۷ رکورد بیماران روان‌پریشی، ۱۶۶ رکورد بیماران اوتیسم، ۱۶۵ رکورد بیماران افسردگی، ۱۶۳ رکورد بیماران اسکیزوفرنی و ۱۶۰ رکورد بیماران اختلال شخصیت بود. مراحل مختلف انجام تحقیق حاضر در شکل ۱ به‌طور خلاصه تشریح شده‌اند.



شکل ۱: فلوچارت روش تحقیق

مجموعه داده گردآوری شده شامل اطلاعات دموگرافیک بیماران اعم از سن، جنس، وزن، وضعیت تأهل، قد، ویژگی‌های جسمی مثل شاخص توده بدنی، بیماری جسمی و ویژگی‌های رفتاری مثل اعتیاد، تنبلی، ضعف حافظه، ترومای دوران کودکی و ... است. شش رده (کلاس یا برچسب) اختلال خلقی ۱-دوقطبی، ۲-افسردگی، ۳-اوتیسم، ۴-اسکیزوفرنی، ۵-اختلال شخصیت و ۶-روان‌پریشی برچسب‌گذاری و به‌صورت اسمی ذخیره شدند. این شش رده با تابع OrdinalEncoder پایتون با اعداد ۰ تا ۵ کدگذاری شدند و در محاسبات تحلیلی مورد استفاده قرار گرفتند.

پس از تهیه مجموعه داده، ویژگی‌های اصلی و مؤثر با کمک متخصصان و مرور ادبیات تحقیق مشخص شدند و پیش‌پردازش داده‌ها صورت گرفت. مقادیر مفقوده، داده‌های نامعلومی هستند که مقدار مشخصی برای آن‌ها متصور نیست و می‌توانند الگوریتم‌ها را گمراه کنند. با توجه به این که داده‌ها از طریق پرسشنامه‌های تکمیل شده به دست آمده بودند، باید فاقد مقادیر مفقوده می‌بودند؛ برای اطمینان از صحت داده‌ها، این موضوع

بررسی شد. در مرحله بعد برخی فیلدهای اضافی و بی‌تأثیر در طبقه‌بندی بیماری به‌صورت شهودی و با مشورت با متخصصان روان‌پزشکی حذف شده و از ابعاد مسئله کاسته شد. این مرحله، یک مرحله کاهش ویژگی استاندارد نیست و کاهش ویژگی باید در فاز مهندسی ویژگی و با استفاده از روش‌ها و رویکردهای کاهش ویژگی انجام شود. کاری که در این مرحله صورت گرفت، در واقع مقدمه‌ای است بر مرحله اصلی مهندسی ویژگی و باعث بالا رفتن کیفیت کار در مراحل بعدی شد. حذف برخی فیلدها از طریق ایجاد فیلدهای جدید صورت گرفت. به‌عنوان مثال تاریخ پذیرش و تاریخ ترخیص حذف و به‌جای آن، ویژگی مدت بستری از تفریق دو تاریخ ایجاد شد. در این مرحله تعداد ویژگی‌ها از ۱۳۰ به ۱۲۲ عدد کاهش پیدا کرد. برای کاهش بیشتر ابعاد داده‌ها با بررسی همبستگی بین دوبه‌دوی ویژگی‌ها و بر اساس آستانه همبستگی با فرض برابر بودن همبستگی قوی با مقدار ۰/۸۵، از متغیرهای همبسته قوی (بالتر از ۰/۸۵) صرف‌نظر شد. بدین ترتیب، تعداد ویژگی‌ها از ۱۲۲ به ۹۱ ویژگی کاهش یافت که در جدول ۱ تشریح شده‌اند.

جدول ۱: ویژگی‌های (متغیرهای) دیتاست بیماران

ردیف	عنوان فارسی ویژگی	عنوان انگلیسی ویژگی	نوع داده	مقدار و دامنه	توضیح
۱	جنس	sex	Binary	مرد=۰، زن=۱	
۲	سن	age	Numeric	۱۶-۷۸ سال	
۳	مدت کل اقامت	the total length of residence	Numeric	۱-۱۵۰	
۴	نوبت بستری	the turn of the hospitalization	Numeric	۱-۲۲	
۵	قد	height	Numeric	۱۰۰-۱۹۰	
۶	شاخص توده بدنی	BMI	Numeric	۱۵٫۵-۷۶	
۷	سابقه بستری یا مراجعه به روان‌پزشک	of admission or history referral to psychiatrist	Binary	۰ و ۱	خیر=۰، بله=۱
۸	مراجعه سرپایی به روان‌پزشک	opportunity to psychiatrist	Binary	۰ و ۱	خیر=۰، بله=۱
۹	چند بار مراجعه سرپایی	outpatient	Numeric	۰-۲۱	
۱۰	تأهل	marital status	Numeric	۱ و ۲ و ۳ و ۴ و ۵	۱=مجرد، ۲=متاهل، ۳=زندگی جدا از همسر، ۴=مطلقه، ۵=همسر فوت‌شده
۱۱	سن شروع بیماری	age of the start of the disease	Numeric	۱ و ۲ و ۳ و ۴ و ۵ و ۶ و ۷ و ۸	۱=۱-۱۰ سال، ۲=۱۱-۲۰ سال، ۳=۲۱-۳۰ سال، ۴=۳۱-۴۰ سال، ۵=۴۱-۵۰ سال، ۶=۵۱-۶۰ سال، ۷=۶۱-۷۰ سال، ۸=بالای ۷۰ سال
۱۲	شغل	job	Numeric	۱ و ۲ و ۳ و ۴ و ۵ و ۶ و ۷ و ۸	۱=کارمند، ۲=آزاد، ۳=بیکار، ۴=خانه‌دار، ۵=محصل، ۶=کارگر، ۷=بازنشسته، ۸=سایر
۱۳	تحصیلات	education	Numeric	۱ و ۲ و ۳ و ۴ و ۵ و ۶ و ۷ و ۸	۱=بی‌سواد، ۲=ابتدایی، ۳=سیکل، ۴=دیپلم، ۵=کاردانی، ۶=لیسانس، ۷=فوق‌لیسانس، ۸=دکتری
۱۴	نوع ترخیص	type of clearance	Numeric	۱ و ۲ و ۳	۱=دائم، ۲=رضایتی، ۳=فراری
۱۵	فصل بیماری	season of disease	Numeric	۱ و ۲ و ۳ و ۴ و ۵	۱=بهار، ۲=تابستان، ۳=پاییز، ۴=زمستان
۱۶	فاصله زمانی شروع علائم و بستری	the time interval of signs and admission	Numeric	۱ و ۲ و ۳	۱=کمتر از یک هفته، ۲=یک ماه، ۳=بیشتر از یک ماه
۱۷	نوع انتقال بیمار به بیمارستان	patient transfer type to hospital	Numeric	۱ و ۲ و ۳ و ۴ و ۵ و ۶	۱=بستگان درجه اول، ۲=بستگان درجه دوم، ۳=دوست/همکار، ۴=اورژانس، ۵=انتقال از مرکزی دیگر، ۶=تامه قضایی
۱۸	مصرف مواد	consumption of materials	Numeric	۱ و ۲ و ۳ و ۴	۱=بله، ۲=خیر، ۳=مشکوک، ۴=ثبت‌نشده
۱۹	نوع مواد مصرفی	type of consumables	Numeric	۱ و ۲ و ۳ و ۴ و ۵ و ۶ و ۷ و ۸	۰=ندارد، ۱=تریاک، ۲=سیگار، ۳=شیشه، ۴=متادون، ۵=الکل، ۶=ترامادول، ۷=مورفین، ۸=حشیش، ۹=کراک، ۱۰=مشکوک
۲۰	سابقه بیماری زمینه‌ای	a history of underlying illness	Numeric	۱ و ۲ و ۳	۱=بله، ۲=خیر، ۳=نامعلوم
۲۱	نوع بیماری زمینه‌ای	type of underlying disease	Numeric	۱ و ۲ و ۳ و ۴ و ۵ و ۶ و ۷ و ۸ و ۹ و ۱۰ و ۱۱ و ۱۲ و ۱۳ و ۱۴ و ۱۵ و ۱۶	۱=خبر، ۲=مغز و اعصاب، ۳=عقونی، ۴=داخلی، ۵=ترمیمی، ۶=روان، ۷=پوست، ۸=گوش و حلق و بینی، ۹=جراح عمومی، ۱۰=نوروسرجری، ۱۱=جراح عروق، ۱۲=رادیولوژی، ۱۳=توان‌بخشی، ۱۴=چشم، ۱۵=تغذیه، ۱۶=قلب
۲۲	بیمه	insurance	Numeric	۱ و ۲	۱=بله، ۲=خیر
۲۳	نوع بیمه	insurance type	Numeric	۱ و ۲ و ۳ و ۴ و ۵	۰=ندارد، ۱=تأمین اجتماعی، ۲=خدمات درمانی، ۳=نیروی مصلح، ۴=کمیته امداد، ۵=آزاد

۱۱۲

۵۶	عملکرد اجرایی ضعیف	poor executive function	Binary	۱ و ۰	۰=خیر، ۱=بله
۵۷	اختلال در حافظه فعال	disruption of active memory	Binary	۱ و ۰	۰=خیر، ۱=بله
۵۸	عدم انگیزه	lack of motivation	Binary	۱ و ۰	۰=خیر، ۱=بله
۵۹	عدم آگاهی از بیماری	lack of knowledge of illness.	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۰	بیان ضعیف احساسات	poor expression of feelings	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۱	افزایش اشتها	increased appetite	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۲	خلق و خوی افسرده	depressed mood	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۳	اضطراب	anxiety	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۴	شکاکیت	skeptical	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۵	گوشه گیری	calling	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۶	ناتوانایی در تصمیم گیری	disabling in decision making	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۷	دوری از مسئولیت ها	away from responsibilities	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۸	ترس از ترد شدن	fear of crispy	Binary	۱ و ۰	۰=خیر، ۱=بله
۶۹	حساسیت بیش از حد نسبت به انتقاد	excessive sensitivity to criticism	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۰	بدبینی	pessimism	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۱	اجتناب از مخالفت	avoid opposition	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۲	مشکل با تنهایی	the problem with loneliness	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۳	ارجح دانستن نیاز دیگران	preferred to know the need for others	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۴	ناشنوا	deaf	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۵	رفتارهای تکراری	duplicate behaviors	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۶	ناتوانی در گفتن اسم	inability to say name	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۷	ناتوانی از شروع مکالمه	inability to start a conversation	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۸	تشنج	convulsion	Binary	۱ و ۰	۰=خیر، ۱=بله
۷۹	استعداد خاص	special talent	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۰	شکست در گذشته	failed in the past	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۱	کاهش تحمل درد	reduce pain tolerance	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۲	تمایل به حمایت اجتماعی	tendency to social support	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۳	عقب ماندگی ذهنی	mental retardation	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۴	گیجی	confusion	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۵	پراکنده	diffused	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۶	نقص شناختی	cognitive impairment	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۷	از دست دادن احساس گرم نسبت به خانواده یا دوستان	loss of warm feelings to family or friends	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۸	سوء مصرف مواد	drug abuse ²	Binary	۱ و ۰	۰=خیر، ۱=بله
۸۹	هیپوکندریازیس	hypochondriasis	Binary	۱ و ۰	۰=خیر، ۱=بله
۹۰	تکانه خودکشی	suicidal impulses	Binary	۱ و ۰	۰=خیر، ۱=بله
۹۱	ترومای کودکی	childhood trauma	Binary	۱ و ۰	۰=خیر، ۱=بله

روش تحلیل مؤلفه اصلی (Principal Component Analysis) PCA راهکاری برای کاهش ابعاد مسئله تحقیق بود. ضرورت استاندارد بودن داده‌های ورودی مورد بررسی در این روش با هدف دوری از داده‌های پرت و قرارگیری در یک مقیاس عددی، دلیلی بر استفاده از تابع StandardScaler کتابخانه پیش‌پردازش SKlearn بود. با اعمال این تابع روی داده‌ها، تمامی داده‌های جدید از توزیع گوسی پیروی کردند و دارای میانگین صفر و انحراف استاندارد ۱ شدند. در این تحقیق، از تابع PCA کتابخانه Scikit-learn پایتون برای کاهش ابعاد مسئله استفاده شد و مقدار n_components (کم‌ترین تعداد ویژگی‌ها) برابر با ۳۵ در نظر گرفته شد. این مقدار با بررسی نمودار PCA که بیانگر جای‌گیری ۹۰ درصد واریانس در ۳۵ مؤلفه اصلی بود، انتخاب شد. برای svd_solver نیز از مقدار full استفاده شد که پس از انجام کل محاسبات، بردارهای ویژه کم‌اهمیت را حذف کرد. در زبان پایتون پس از کاهش ویژگی، مجموعه داده در اختیار الگوریتم‌های یادگیری ماشین قرار گرفت. الگوریتم‌های یادگیری ماشین روی مجموعه داده‌ها آموزش دیده و آزمایش شدند تا دقت طبقه‌بندی بیماران طبق شش رده اختلال خلقی بر اساس داده‌های موجود روی داده‌های آموزش ندیده بررسی شود. مسئله تعیین اختلالات خلقی بر اساس داده‌های پرسشنامه‌های اختلالات خلقی، از نوع طبقه‌بندی چند رده‌ای (Multi-Class Classification) است. الگوریتم‌های طبقه‌بندی یادگیری ماشین مناسب چند رده‌ای مورد استفاده عبارت‌اند از: K نزدیک‌ترین همسایه (K-Nearest)، KNN(Neighbors)، درخت تصمیم (Decision Tree)، نایو بیز NB(Naive Bayes)، جنگل تصادفی (Random Forest)، رگرسیون لجستیک (Logistic)، ماشین بردار پشتیبان (Support Vector Machine)، SVM، الگوریتم KNN یک الگوریتم غیر پارامتریک است که با محاسبه فاصله بین هر نقطه جدید با نقاط داده و رأی‌گیری رده نقطه جدید را اختصاص می‌دهد. الگوریتم KNN به ازای ۵ همسایه استفاده شد (n_neighbors=۵). در الگوریتم درخت تصمیم نمونه‌ها دسته‌بندی می‌شوند. در ساختار درخت تصمیم، پیش‌بینی به دست آمده از درخت در قالب یک سری قواعد توضیح داده می‌شود. هر مسیر از ریشه تا یک برگ درخت تصمیم، یک قانون را بیان می‌کند و در نهایت برگ با رده‌ای که بیشترین مقدار رکورد در آن تعلق گرفته برچسب می‌خورد. max_depth تعیین‌کننده حداکثر عمق درخت است. از عمق هفت برای ساختن

درخت تصمیم خود استفاده شد (max_depth=۷). روش‌های نایو بیز، مجموعه‌ای از الگوریتم‌های یادگیری با نظارت بر اساس به‌کارگیری قضیه بیز با فرض بیز استقلال شرطی بین هر زوج ویژگی و مقدار رده در مجموعه داده است. از تابع GaussianNB از کتابخانه SKLearn پایتون استفاده شد. الگوریتم جنگل تصادفی مجموعه‌ای از الگوریتم‌های درخت تصمیم است. در این الگوریتم هر درخت در مجموعه از نمونه‌ای ساخته می‌شود که با جایگزینی از مجموعه آموزشی ترسیم شده است. max_depth یک درخت در جنگل تصادفی طولانی‌ترین مسیر بین گره ریشه و گره برگ است با استفاده از این پارامتر، می‌توان عمق هر درخت را تعیین نمود که در این جا برابر با ۳ در نظر گرفته شد. رگرسیون لجستیک فرآیند مدل‌سازی احتمال یک خروجی گسسته با داشتن یک متغیر ورودی است. با توجه به این‌که مسئله از نوع چند رده‌ای است، پارامتر multi_class برابر 'multinomial' قرار داده شد. هدف از الگوریتم ماشین بردار پشتیبان به‌عنوان یک طبقه‌بند، یافتن یک ابر صفحه در فضای n بعدی است (n تعداد ویژگی‌هاست) که با دقت بالا نقاط داده را رده‌بندی کند. برای اجرای الگوریتم ماشین بردار پشتیبان از تابع طبقه‌بندی‌کننده ماشین بردار پشتیبان از کتابخانه SKLearn استفاده شد. از بین این الگوریتم‌ها، دو الگوریتمی که دقت بالای ۰/۹۰ داشتند انتخاب شده و با ترکیب با الگوریتم‌های ژنتیک و بهینه‌سازی ازدحام ذرات، سعی شد دقت در طبقه‌بندی افزایش و خطا کاهش یابد.

الگوریتم ژنتیک یک جستجوی اکتشافی است که از نظریه تکامل طبیعی چارلز داروین الهام گرفته شده است. این الگوریتم فرآیند انتخاب طبیعی را منعکس می‌کند که در آن بهترین افراد برای تولیدمثل انتخاب می‌شوند تا فرزندان نسل بعدی تولید شوند. الگوریتم بهینه‌سازی ازدحام ذرات یک رویکرد تصادفی مبتنی بر جمعیت برای حل مسائل بهینه‌سازی پیوسته و گسسته است. در بهینه‌سازی ازدحام ذرات، عامل‌های نرم‌افزاری ساده‌ای که ذرات نامیده می‌شوند، در فضای جستجوی یک مسئله بهینه سازی حرکت می‌کنند. موقعیت یک ذره یک راه‌حل کاندید برای مسئله بهینه‌سازی در دست است. هر ذره با تغییر سرعت خود بر اساس قوانینی که در اصل از مدل‌های رفتاری دسته پرنده‌گان الهام گرفته شده بود، به دنبال موقعیت‌های بهتر در فضای جستجو می‌شود.

معیارهای ارزیابی مدل

چهار معیار ارزیابی Precision، Recall، F1_score و Accuracy در این تحقیق برای ارزیابی کارایی الگوریتم‌ها

استفاده شده است.

و منفی کاذب متقارن باشد. دقت را می‌توان به صورت رابطه ذکر شده تعریف کرد؛ که در آن TP ، FN ، FP و TN به ترتیب تعداد مثبت‌های واقعی، منفی‌های کاذب، مثبت‌های کاذب و منفی‌های واقعی را نشان می‌دهند.

Accuracy: دقت، شهودی‌ترین معیار عملکرد است. این معیار نسبت مشاهدات پیش‌بینی شده به کل مشاهدات است. دقت، زمانی معیار مناسبی است که مجموعه داده‌ها از نظر مثبت کاذب

$$Accuracy = (TP + TN) / (TP + FP + FN + TN)$$

به‌عنوان تعداد اسناد صحیح برگشتی توسط مدل در نظر گرفته می‌شود. صحت از رابطه زیر به دست می‌آید.

Precision: صحت، نسبت مشاهدات مثبت پیش‌بینی شده صحیح به کل مشاهدات مثبت پیش‌بینی شده است. صحت

$$Precision = TP / (TP + FP)$$

رابطه این معیار به شرح زیر است.

Recall: یادآوری (حساسیت) - یادآوری نسبت مشاهدات مثبت پیش‌بینی شده درست به همه مشاهدات در کلاس واقعی است.

$$Recall = TP / (TP + FN)$$

می‌گیرد. این معیار در بهترین حالت یک و در بدترین حالت صفر است و از رابطه زیر به دست می‌آید.

F1_score: معیار $F1$ معیاری مناسب برای ارزیابی دقت یک آزمایش است. این معیار هر دوی صحت و یادآوری را در نظر

$$F1_score = 2 * (Recall * Precision) / (Recall + Precision)$$

الگوریتم‌های داده‌کاوی به کاررفته توسط معیارهای $Precision$ ، $Recall$ و $F1_Score$ ارزیابی شدند. مقادیر حاصل در جدول ۲ برای شش کلاس اوتیسم ($C1$)، دوقطبی ($C2$)، افسردگی ($C3$)، اختلال شخصیت ($C4$)، روان‌پریشی ($C5$) و اسکیزوفرنی ($C6$) به طور مجزا گزارش شده است.

نتایج

نتایج تحقیق حاضر در دو بخش مجزا، شامل نتایج ارزیابی الگوریتم‌های داده‌کاوی و نتایج ترکیب الگوریتم‌های فراابتکاری با الگوریتم‌های داده‌کاوی منتخب ارائه می‌گردد.

نتایج ارزیابی الگوریتم‌ها

جدول ۲: نتایج ارزیابی الگوریتم‌ها با معیارهای مختلف

معیار	Precision	Recall	F1-score	Precision	Recall	F1-score	Precision	Recall	F1-score
کلاس (ده/برچسب)	الگوریتم NB			الگوریتم RL			الگوریتم KNN		
اوتیسم	۰/۸۳	۰/۸۱	۰/۸۲	۰/۸۴	۰/۹	۰/۸۷	۰/۸۹	۰/۸۸	۰/۸۸
دوقطبی	۰/۸۹	۰/۷۹	۰/۸۴	۰/۸۷	۰/۸۴	۰/۸۵	۰/۸۷	۰/۸۷	۰/۸۷
افسردگی	۰/۹۴	۰/۸۳	۰/۸۸	۰/۹۳	۰/۸۵	۰/۸۹	۰/۸۷	۰/۸۵	۰/۸۹
اختلال شخصیت	۰/۹۱	۰/۹۳	۰/۹۲	۰/۹	۰/۹۶	۰/۹۳	۰/۹	۰/۹۶	۰/۹۳
روان‌پریشی	۰/۷۸	۰/۹۱	۰/۸۴	۰/۸۷	۰/۸۹	۰/۸۸	۰/۸۵	۰/۸۹	۰/۸۷
اسکیزوفرنی	۰/۸	۰/۸۹	۰/۸۴	۰/۸۵	۰/۹۳	۰/۹۴	۰/۹۳	۰/۹۳	۰/۹۳
کلاس (ده/برچسب)	الگوریتم RF			الگوریتم DT			الگوریتم SVM		
اوتیسم	۰/۹۲	۰/۹۲	۰/۹۲	۰/۸	۰/۸۵	۰/۸۳	۰/۸۳	۰/۹۲	۰/۸۷
دوقطبی	۰/۸۹	۰/۸۷	۰/۸۸	۰/۷۷	۰/۷۵	۰/۷۶	۰/۸۹	۰/۸۶	۰/۸۷
افسردگی	۰/۹۵	۰/۸۷	۰/۹	۰/۹۱	۰/۸	۰/۸۵	۰/۹۴	۰/۸۵	۰/۸۹
اختلال شخصیت	۰/۹	۰/۹۶	۰/۹۳	۰/۹۱	۰/۹۱	۰/۹۱	۰/۹۳	۰/۹۶	۰/۹۴
روان‌پریشی	۰/۸۵	۰/۸۹	۰/۸۷	۰/۷۶	۰/۸۹	۰/۸۳	۰/۸۷	۰/۸۹	۰/۸۸
اسکیزوفرنی	۰/۹۳	۰/۹۳	۰/۹۳	۰/۸۸	۰/۸۶	۰/۸۷	۰/۹۵	۰/۹۳	۰/۹۴

الگوریتم‌ها محاسبه می‌شود. به عنوان نمونه، مقادیر شش ماتریس درهم‌ریختگی مربوط به الگوریتم جنگل تصادفی در جدول ۳ نشان داده شده است.

برای هر الگوریتم داده‌کاوی، به‌طور مجزا درایه‌های ماتریس درهم‌ریختگی (Confusion Matrix) شش کلاس محاسبه گردید. این ماتریس بیانگر مقادیر TP، FN، FP و TN برای هر کلاس است که با کمک آن‌ها مقدار متوسط دقت برای هر

جدول ۳: ماتریس‌های درهم‌ریختگی ارزیابی الگوریتم RF

پیش‌بینی شده واقعی	C1 +	C1 -	C2 +	C2 -	C3 +	C3 -	C4 +	C4 -	C5 +	C5 -	C6 +	C6 -
C1 +	۴۴	۴										
C1 -	۴	۲۲۰										
C2 +			۵۵	۸								
C2 -			۷	۲۰۲								
C3 +					۵۲	۸						
C3 -					۳	۲۰۹						
C4 +							۵۵	۲				
C4 -							۶	۲۰۹				
C5 +									۳۹	۵		
C5 -									۷	۲۲۱		
C6 +											۵۳	۴
C6 -											۴	۲۲۱

شده‌اند و مابقی به تعداد ۲۲۰ رکورد به درستی در این رده قرار نگرفته‌اند.

متوسط دقت محاسبه شده برای هر یک از الگوریتم‌های به‌کار رفته در تحقیق در جدول ۴ گردآوری شده است. ملاحظه می‌گردد دقیق‌ترین الگوریتم‌ها در پیش‌بینی انواع اختلالات خلقی، به ترتیب جنگل تصادفی و بردار پشتیبان تصمیم هستند.

با توجه به جدول ۳، به‌عنوان مثال، مقادیر TP، FN، FP و TN برای کلاس اوتیسم به ترتیب برابر است با ۴۴، ۴، ۴، ۲۲۰. این بدان معناست که در میان ۳۲۹ رکورد آزمایشی که شامل ۴۸ رکورد مربوط به رده اوتیسم هستند، ۴۴ رکورد به درستی برچسب‌گذاری شده‌اند، ۴ رکورد به اشتباهی در رده دیگری پیش‌بینی شده‌اند، ۴ رکورد به اشتباهی در این رده پیش‌بینی

جدول ۴: مقایسه دقت پیش‌بینی الگوریتم‌های داده‌کاوی

الگوریتم NB	الگوریتم RL	الگوریتم KNN	الگوریتم RF	الگوریتم DT	الگوریتم SVM
۰/۸۶	۰/۸۹	۰/۸۹	۰/۹۱	۰/۸۴	۰/۹۰
دقت (Accuracy)					

شد. در ادامه، نتایج حاصل در چهار زیربخش ارائه می‌گردد.

نتیجه اجرای GA برای تعیین مقادیر بهینه پارامترها

برای تعیین مقادیر بهینه پارامترهای RF، در الگوریتم GA جمعیت اولیه ۳۰ و تعداد نسل‌ها ۱۰ انتخاب گردید. در این رابطه شبه‌کد زیر در پایتون نوشته شد:

```
evolved_estimator = GASearchCV(estimator= RandomForestClassifier,
                                cv=cv,
                                scoring='accuracy',
                                param_grid=param_grid,
                                population_size=30,
                                generations=10,
                                n_jobs=-1,
                                verbose=True)
```

نتایج ترکیب الگوریتم‌های فراابتکاری با الگوریتم‌های داده‌کاوی

همان‌طور که در جدول ۴ نشان داده شده است، در میان شش الگوریتم پیشنهادی، الگوریتم‌های RF و SVM دقت ۰/۹ و بالاتر را کسب نمودند؛ لذا از الگوریتم ژنتیک و بهینه‌سازی ازدحام ذرات برای تعیین مقادیر بهینه پارامترهای آن‌ها استفاده


دست آمده برابر با ۹۰/۵۷ درصد است.

نتیجه ترکیب الگوریتم‌های PSO و RF

در بهینه‌سازی ازدحام ذرات هدف کمینه کردن خطا در تابع هدف است. در این تحقیق، مقادیر پارامترهای الگوریتم PSO برای تعداد ذرات (N)، تعداد تکرار الگوریتم (T)، ضریب اینرسی (W)، ضریب شخصی (C1)، و ضریب اجتماعی (C2) به ترتیب برابر با ۳۰، ۱۵۰، ۰/۹، ۲، و ۲ تنظیم گردید. نتیجه ترکیب الگوریتم بهینه‌سازی ازدحام ذرات و جنگل تصادفی در شکل ۲ نمایش داده شده است.

در این شبه کد، CV به معنای تعداد فولدها در Cross-validation و scoring نشان‌دهنده نوع معیار ارزیابی الگوریتم است. param_grid مجموعه پارامترهای تعیین شده برای الگوریتم و n_jobs=-۱ به معنای استفاده از حداکثر توان CPU و در نهایت verbose نشان‌دهنده خروجی با دقت به دست آمده است. دقت به دست آمده برابر با ۹۰/۵۷ درصد است.

همچنین، برای تعیین مقادیر بهینه SVM، در الگوریتم GA، جمعیت اولیه ۵۰ و تعداد نسل‌ها ۸۰ انتخاب شد. دقت به




شکل ۲: نمودار ارزیابی PSO-RF

شد. نتیجه اجرای ترکیب این الگوریتم با الگوریتم ماشین بردار پشتیبان در شکل ۳ به نمایش درآمده است. دقت مدل طراحی شده پس از ۱۰۰ تکرار و با انتخاب ۴۵ ویژگی برابر با ۹۳/۳۰۴۳ درصد بوده است.

برای این طراحی، پس از ۱۰۰ تکرار و با انتخاب ۳۴ ویژگی، دقتی برابر با ۹۱/۳۰۴۳ درصد حاصل گردید.

نتیجه ترکیب الگوریتم‌های PSO و SVM

مشابه قبل، برای پارامترهای الگوریتم PSO، مقادیر N، T، W، C1 و C2 به ترتیب برابر با ۳۰، ۱۵۰، ۰/۹، ۲، و ۲ در نظر گرفته



شکل ۳: نمودار ارزیابی PSO-SVM

در شکل‌های ۲ و ۳، مقادیر محور عمودی عبارت است از اختلاف بین مقدار پیش‌بینی شده متغیر هدف و متغیر هدف واقعی در تکرارهای مختلف. به بیان دیگر، محور عمودی، مقادیر تابع هزینه PSO را نشان می‌دهد و بر اساس کمترین مقدار تابع هزینه تعداد ویژگی‌ها به‌دست می‌آید.

بحث و نتیجه‌گیری

در این پژوهش مسئله طبقه‌بندی بیماران اختلالات خلقی بررسی شده است. با توجه به اهمیت نشاط در جامعه و ضرورت کاهش زمان تشخیص اولیه بیماری‌های روانی خلقی و اتخاذ رویکرد روان‌درمانی مناسب هر یک، موضوع تحقیق از اهمیت ویژه‌ای برخوردار است. برای بهبود دقت از الگوریتم‌های ژنتیک و بهینه‌سازی ازدحام ذرات یاری گرفته شد. ترکیب با ژنتیک دقت دو الگوریتم ماشین بردار پشتیبان و جنگل تصادفی را چندان بهبود نمی‌دهد. این امر می‌تواند به دلیل مشکل بهینه محلی (Local Minimal) باشد که یکی از اشکالات شایع الگوریتم ژنتیک است و زمانی اتفاق می‌افتد که الگوریتم بهترین محلی را با بهترین سراسری اشتباه می‌گیرد. از سوی دیگر، الگوریتم بهینه‌سازی ذرات در ترکیب با هر دو الگوریتم جنگل تصادفی و ماشین بردار پشتیبان باعث بهبود قابل قبولی در دقت پیش‌بینی می‌شود. نتایج ترکیب الگوریتم ماشین بردار پشتیبان و ازدحام ذرات با $93/30$ درصد نسبت به ترکیب الگوریتم جنگل تصادفی و ازدحام ذرات با $91/97$ درصد دقت عملکرد بالاتری نشان می‌دهد و کاندید مناسبی برای اعمال طبقه‌بندی روی مجموعه داده‌های مسئله است.

مقایسه نتایج تحقیق حاضر با پژوهش‌های مشابه نشان می‌دهد درمیان الگوریتم‌های به‌کار گرفته شده، دو الگوریتم جنگل

تصادفی با دقت 91 و ماشین بردار پشتیبان با دقت 90 درصد عملکرد بهتری نشان داده‌اند. دقت مدل یادگیری عمیق ارائه شده توسط Liu و همکاران [۱۴] 65 درصد، مدل جنگل تصادفی مورد استفاده Rotenberg و همکاران [۲۷] 80 درصد، مدل یادگیری ماشین Bayes و همکاران [۲۸] $73/9$ درصد، مدل ترکیبی مورد استفاده Eeden و همکاران [۱۲] 79 درصد، مدل ترکیبی Liu و همکاران $87/5$ درصد [۸] و مدل‌های Nguyen و همکاران [۲۹] $0/86$ و $0/79$ ، برآورد شده بود.

مدل‌های طراحی شده در این تحقیق، PSO-RF و PSO-SVM، دستاورد مهمی برای طراحی سیستم پشتیبان تصمیم کلینیک‌های روان‌پزشکی است. با توجه به محدودیت‌های مسئله از جمله کوچک بودن ابعاد مجموعه داده، در آینده می‌توان با جمع‌آوری پرسشنامه‌های بیشتر، مجموعه داده‌های غنی‌تری تهیه کرد تا نتایج تحقیق تعمیم‌پذیر گردد. همچنین، پیشنهاد می‌گردد الگوریتم‌های یادگیری عمیق و یا الگوریتم‌های داده‌کاوی فازی برای مدل‌سازی به‌کار گرفته شوند.

تشکر و قدردانی

این مقاله مستخرج از پایان‌نامه کارشناسی ارشد گروه مهندسی صنایع با عنوان «استفاده از روش‌های داده‌کاوی برای پیش‌بینی و تشخیص بیماری دوقطبی» است که در سال 1400 در دانشگاه آزاد اسلامی تهران واحد علوم تحقیقات انجام گردید.

تعارض منافع

نویسندگان مقاله اعلام می‌کنند که این پژوهش هیچ‌گونه تعارض منافی ندارد.

References

1. Parsapour F, Peymani J. Using Data Mining Techniques for Intelligent Diagnosis of Severity of Depressive Disorder. Journal of Health and Biomedical Informatics 2020;7(3):252-62. [In Persian]
2. World health organization (WHO). Depression; 2022 [cited 2021 May 1]. Available from: <https://www.who.int/news-room/fact-sheets/detail/depression>
3. Mansourian M, Khademi S, Marateb HR. A comprehensive review of computer-aided diagnosis of major mental and neurological disorders and suicide: a biostatistical perspective on data mining. Diagnostics 2021;11(3):393. 10.3390/diagnostics11030393
4. Guo T, Zhao W, Alrashoud M, Tolba A, Firmin S, Xia F. Multimodal Educational Data Fusion for

- Students'Mental Health Detection. IEEE Access 2022;10:70370-82. 10.1109/ACCESS.2022.3187502
5. Vigo D, Thornicroft G, Atun R. Estimating the true global burden of mental illness. The Lancet Psychiatry 2016;3(2):171-8. 10.1016/S2215-0366(15)00505-2
6. König H, König HH, Konnopka A. The excess costs of depression: a systematic review and meta-analysis. Epidemiology and psychiatric sciences. Epidemiology and Psychiatric Sciences 2020; 29: e30. 10.1017/S2045796019000180
7. Baumeister H, Hutter N, Bengel J, Härter M. Quality of life in medically ill persons with comorbid mental disorders: a systematic review and meta-analysis. Psychotherapy and Psychosomatics 2011;80(5):275-86. 10.1159/000323404
8. Liu YS, Chokka S, Cao B, Chokka PR. Screening for bipolar disorder in a tertiary mental health center using

- EarlyDetect: A machine learning-based pilot study. *Journal of Affective Disorders Reports* 2021;6:100215.
9. Sadr Ameli H. The effect of topiramate on bipolar mood disorder [dissertation]. Tehran: Shahid Beheshti University of Medical Sciences; 2014. [In Persian]
 10. James SB, Alcott SV. Kaplan and Sadock's Concise Textbook of Clinical Psychiatry. 3rd ed. Philadelphia: Lippincott Williams & Wilkins; 2008.
 11. Isometsä E. Suicidal behaviour in mood disorders— who, when, and why?. *The Canadian Journal of Psychiatry* 2014;59(3):120-30. 10.1177/070674371405900303
 12. van Eeden WA, Luo C, van Hemert AM, Carlier IV, Penninx BW, Wardenaar KJ, et al. Predicting the 9-year course of mood and anxiety disorders with automated machine learning: A comparison between auto-sklearn, naïve Bayes classifier, and traditional logistic regression. *Psychiatry Research* 2021;299:113823. 10.1016/j.psychres.2021.113823
 13. Lei Y, Belkacem AN, Wang X, Sha S, Wang C, Chen C. A convolutional neural network-based diagnostic method using resting-state electroencephalograph signals for major depressive and bipolar disorders. *Biomedical Signal Processing and Control* 2022;72:103370. 10.1016/j.bspc.2021.103370
 14. Liu Y, Qu HQ, Mentch FD, Qu J, Chang X, Nguyen K, et al. Application of deep learning algorithm on whole genome sequencing data uncovers structural variants associated with multiple mental disorders in African American patients. *Molecular Psychiatry* 2022;27(3):1469-78.
 15. Molavi P, Salvat H, Aghdam NS, Mohammadi MN. The efficacy of Cognitive-Behavioral Therapy (CBT+ TAU) on reducing type-I Bipolar disorder symptoms. *Shenakht Journal of Psychology and Psychiatry* 2018;7(2):92-103. [In Persian] 10.52547/shenakht.7.2.92
 16. Tari Barazin N, Babapour J, Aghdasi A. Comparison of the effectiveness of social skills training and training of cognitive emotion regulation strategies on social adjustment and positive and negative emotions in Man with type I bipolar disorder. *Journal of Applied Family Therapy* 2021;2(4):137-57.
 17. Phillips M, Kupfer D. Bipolar disorder diagnosis: challenges and future directions. *Lancet* 2013;381(9878):1663-71. 10.1016/S0140-6736(13)60989-7.
 18. Han J, Kamber M, Mining D. Concepts and techniques. Morgan Kaufmann 2006;340:94104-3205.
 19. Shailaja K, Seetharamulu B, Jabbar MA. Machine learning in healthcare: A review. Second International Conference on Electronics, Communication and Aerospace Technology (ICECA); 2018 Mar 29; Coimbatore, India: IEEE; 2018. p. 910-4. 10.1109/ICECA.2018.8474918
 20. Bleidorn W, Hopwood CJ. Using machine learning to advance personality assessment and theory. *Personality and Social Psychology Review* 2019;23(2):190-203. 10.1177/1088868318772990
 21. Chancellor S, De Choudhury M. Methods in predictive techniques for mental health status on social media: a critical review. *NPJ Digital Medicine* 2020;3(1):1.
 22. Llamocca P, Urgelés D, Cukic M, Lopez V. Bip4Cast: Some advances in mood disorders data analysis. 1st International 'Alan Turing' Conference on Decision Support and Recommender Systems (DSRS-Turing'19); 2019 Nov 21-22; London: The Alan Turing Institute; 2019.
 23. Čukić M, López V. Progress in Objective Detection of Depression and Online Monitoring of Patients Based on Physiological Complexity. *Frontiers in Psychiatry* 2022;13:828773.
 24. Mallick S, Panda M. Application of Deep Learning in Mental Disorder: Challenges and Opportunities. *Next Generation Healthcare Informatics* 2022:295-308.
 25. Squarcina L, Villa FM, Nobile M, Grisan E, Brambilla P. Deep learning for the prediction of treatment response in depression. *Journal of Affective Disorders* 2021;281:618-22. 10.1016/j.jad.2020.11.104
 26. Najafabadi MM, Villanustre F, Khoshgoftaar TM, Seliya N, Wald R, Muharemagic E. Deep learning applications and challenges in big data analytics. *Journal of Big Data* 2015;2(1):1-21.
 27. de Siqueira Rotenberg L, Borges-Júnior RG, Lafer B, Salvini R, da Silva Dias R. Exploring machine learning to predict depressive relapses of bipolar disorder patients. *Journal of Affective Disorders* 2021;295:681-7. 10.1016/j.jad.2021.08.127
 28. Bayes A, Spoelma MJ, Hadzi-Pavlovic D, Parker G. Differentiation of bipolar disorder versus borderline personality disorder: A machine learning approach. *Journal of Affective Disorders* 2021;288:68-73. 10.1016/j.jad.2021.03.082
 29. Nguyen DK, Chan CL, Li AH, Phan DV, Lan CH. Decision support system for the differentiation of schizophrenia and mood disorders using multiple deep learning models on wearable devices data. *Health Informatics Journal* 2022;28(4):14604582221137537. 10.1177/1460458222113753