

طراحی طبقه‌بندهای شورایی ابتکاری با قابلیت اطمینان بالا

زینب خاتون پورطاهری^۱، سید حمید ظهیری^{۲*}، سید محمد رضوی^۳

۱- دانشجوی دکتری، ۲- استاد، ۳- دانشیار، دانشگاه بیرجند

(دریافت: ۹۵/۰۳/۱۰، پذیرش: ۹۵/۱۰/۰۹)

چکیده

قابلیت اطمینان در تصمیم‌سازی یک طبقه‌بند، گاه از میزان تشخیص صحیح آن مهم‌تر است. کاربردهای نظامی و امنیتی مصادیق روشنی از اهمیت این عامل است. مثلاً ناتوانی یک سامانه بازشناسی خودکار اهداف رادار در تشخیص انواع هواپیماهای نظامی، خطای آن را زیاد می‌کند اما تصمیم همین سامانه در خصوص تشخیص اهداف نظامی باید با قابلیت اطمینان حداکثر توأم باشد و هرگز نباید یک هدف غیر نظامی را نظامی تلقی کند. در این مقاله، با استفاده از روش‌های ابتکاری چند هدفه، یک طبقه‌بند شورایی با قابلیت اطمینان بالا معرفی می‌شود. علاوه بر این، سایز شورا و نرخ خطا نیز کمینه شده است. روش‌های مورد استفاده عبارتند از الگوریتم‌های بهینه‌سازی ازدحام ذرات چند هدفه و سامانه صفحات شیب‌دار چند هدفه که روش اخیر برای نخستین بار در طراحی طبقه‌بندهای شورایی به کار گرفته شده است. با توجه به توانایی روش‌های مذکور در ارائه جبهه پرتو، امکان ایجاد شرایط متنوع و دلخواه کاربر نیز مهیا است. شرایطی که در آن اهمیت هر یک از معیارها قوت و ضعف پیدا می‌کند.

کلیدواژه‌ها: طبقه‌بندهای شورایی، قابلیت اطمینان، الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار چند هدفه، انتخاب طبقه‌بند

Design of Heuristic Ensemble Classifiers with High Reliability

Z. Pourtaheri, S. H. Zahiri*, S. M. Razavi

University of Birjand

(Received: 30/05/2016; Accepted: 29/12/2016)

Abstract

Sometimes, the reliability in decision of a classifier is more important than its recognition rate. Military and security applications are clear examples to show the importance of this measure. For example, the inability of an automatic targets recognition system to distinguish all types of military planes increases its error rate but the decision of this system for recognition of military targets should be accompanied with maximum reliability and never should be considered a civilian as a military target. This paper presents an ensemble classifier with high reliability by using multi-objective heuristic methods. Moreover, ensemble size and error rate have been minimized. Multi-Objective Particle Swarm Optimization Algorithm and Multi-Objective Inclined Planes Optimization Algorithm are the multi-objective heuristic methods which are used in this paper. The recent method is applied to design ensemble classifiers for the first time. Due to the ability of multi-objective heuristic methods in presentation of the Pareto front, it's possible to create various and user-defined conditions; conditions in which the importance of each factor (ensemble size, error rate and reliability) can be strengthened and weakened.

Keywords: Ensemble Classifier, Reliability, Multi-Objective Inclined Planes Optimization Algorithm, Classifier Selection

* Corresponding Author E-mail: hzahiri@birjand.ac.ir

۱. مقدمه

می‌شود. شایسته‌ترین طبقه‌بندهای پایه، جمعیتی تشکیل می‌دهند که در نهایت، شورا را می‌سازند. تابع هدف به کاررفته به صورت ترکیبی از دقت و گوناگونی تعریف می‌شود.

انتخاب طبقه‌بندهای شرکت‌کننده در شورا به صورت هم‌زمان با انتخاب قانون ترکیب با به‌کارگیری الگوریتم ژنتیک توسط سیرلنتزیس و همکاران [۷] انجام شده است که در آن تابع هدف به صورت نرخ بازشناسی روی مجموعه داده‌های ارزیابی (که پیش از این برای سامانه ناشناخته بوده‌اند) تعریف می‌شود. کونولی و همکاران [۸] برای ساخت شورای طبقه‌بندها از الگوریتم بهینه‌سازی ازدحام ذرات چند هدفه با توابع هدف نرخ خطا و سبب شبکه استفاده کرده‌اند.

همان‌طور که در مرور تحقیقات فوق نیز مشاهده می‌شود، نرخ خطا و سبب شورا به عنوان دو تابع هدف مهم در روش‌های شورایی در نظر گرفته می‌شوند. این در حالی است که اکثر پژوهش‌ها از معیارهای مهم دیگر غافل شده‌اند، یکی از این معیارها قابلیت اطمینان است. توضیح اینکه در برخی طبقه‌بندها، معیار قابلیت اطمینان نسبت به نرخ تشخیص صحیح از اهمیت بیشتری برخوردار است. در این تحقیق، علاوه بر اهداف نرخ خطا و سبب شورا، برای اولین بار قابلیت اطمینان به عنوان معیاری جهت طراحی طبقه‌بندهای شورایی لحاظ شده است.

از آنجا که اهمیت افزودن معیار قابلیت اطمینان در کاربردهای امنیتی و نظامی است، خالی از لطف نخواهد بود که به برخی از کارهای انجام شده در زمینه امنیتی اشاره کرد. مهنا و همکاران [۹] یک رادار مولتی‌استاتیک را طراحی و شبیه‌سازی کرده‌اند که در فضای سه بعدی قادر به آشکارسازی اجسام پرنده در ناحیه تحت پوشش، محاسبه مکان و سرعت، مسیر و تشخیص نوع شیء با محاسبه سطح مقطع راداری آن است. با توجه به تأثیر محل قرار گرفتن ایستگاه‌های رادار در میزان سطح سیگنال به نویز و سطح پوشش رادار، در این مقاله، محل قرار گرفتن ایستگاه‌های رادار نیز با استفاده از الگوریتم ژنتیک چند هدفه بهینه‌سازی شده است، به گونه‌ای که با کمترین تعداد ایستگاه فرستنده و گیرنده، بیشترین میزان سیگنال به نویز و سطح پوشش رادار در فضای سه بعدی حاصل شود.

ناصری و سعادت [۱۰] الگوریتمی هوشمند برای خوشه‌بندی، تشخیص مدولاسیون بین پالسی و جداسازی و شناسایی رشته پالس‌های متداخل رادارها ارائه کرده‌اند. در الگوریتم پیشنهادی برای خوشه‌بندی پالس‌های متداخل دریافتی از شبکه عصبی خود سازمانده و تشخیص نوع مدولاسیون بین پالسی از روش ضرب ماتریسی و برای شناسایی نوع رادار از شبکه عصبی RBF استفاده شده است. علائی و همکاران [۱۱] به منظور

طبقه‌بندی شورایی مقوله‌ای است که در آن مجموعه‌ای از طبقه‌بندهای مجزا آموزش می‌بینند و سپس نتایج آن‌ها به منظور تصمیم‌سازی نهایی باهم ترکیب می‌شوند [۱]. هنگام کار کردن با طبقه‌بندهای شورایی، ممکن است دو راهبرد مختلف به کار گرفته شوند: ادغام و انتخاب. در ادغام تصمیمات طبقه‌بندهای پایه، فرض بر این است که هر عضو شورا روی کل فضای ویژگی، آموزش می‌بیند اما در انتخاب طبقه‌بند، هر عضو برای یادگیری قسمتی از فضای ویژگی اختصاص می‌یابد؛ بنابراین در روش ادغام، تصمیم نهایی با در نظر گرفتن تصمیم‌های همه اعضا ایجاد می‌شود و در راهبرد انتخاب، تصمیم نهایی، نتیجه‌ای از تصمیم‌های یک یا تعدادی از خبره‌هاست. هم‌چنین روش‌های ترکیبی وجود دارند که بین این دو راهبرد قرار می‌گیرند؛ از آن جمله می‌توان به روش OCS^۱ (راهبرد انتخاب و تولید اضافی) [۲] اشاره نمود. با فرض وجود افزونگی بین طبقه‌بندها، هدف این روش، پیدا کردن مناسب‌ترین زیرمجموعه از طبقه‌بندها است. وقتی که بهترین زیرمجموعه از طبقه‌بندها انتخاب شد، زمان ترکیب خروجی‌های آن‌ها فرامی‌رسد [۳]. OCS یک مسئله‌ی بهینه‌سازی است که می‌تواند با استفاده از الگوریتم‌های جستجو انجام شود. در این حالت، انتخاب بهترین الگوریتم جستجو و بهترین معیار جستجو دو مقوله‌ی مهم به شمار می‌روند [۴].

راهبردهای مرتبط با فاز انتخاب OCS عبارت‌اند از الگوریتم‌های جستجوی تک هدفه و چند هدفه. داس سنتوس [۴] برای انتخاب مناسب‌ترین زیرمجموعه‌ی طبقه‌بندها از پنج الگوریتم بهینه‌سازی ابتکاری استفاده کرده است؛ سه الگوریتم ژنتیک چند هدفه و الگوریتم ژنتیک و ازدحام ذرات تک‌هدفه. توابع هدف در نظر گرفته‌شده توسط وی برای الگوریتم‌های ژنتیک چند هدفه عبارت‌اند از سبب شورا و نرخ خطا درحالی‌که برای الگوریتم‌های تک هدفه، نرخ خطا به عنوان تابع هدف لحاظ شده است.

ینگ و همکاران [۵] با الهام گرفتن از این نکته که حذف طبقه‌بندهای ضعیف، عملکرد طبقه‌بندی را بهبود می‌دهد و با به‌کارگیری الگوریتم بهینه‌سازی ازدحام ذرات تک هدفه با تابع هدف نرخ خطا، انتخاب و ترکیب طبقه‌بندها را به طور هم‌زمان انجام داده‌اند. اپیتز [۶] ابتدا با ساخت جمعیت اولیه‌ای از طبقه‌بندها که هر کدام با انتخاب تصادفی زیرمجموعه‌ی متفاوتی از ویژگی‌ها ایجاد شده‌اند شروع به کار می‌کند. سپس با استفاده از اپراتورهای الگوریتم ژنتیک روی زیرمجموعه‌های ویژگی، کاندیدهای جدیدی از فضای ویژگی برای طبقه‌بندها ساخته

¹ Overproduce and Choose Strategy

منظور، در سامانه‌های معمولی بازنمایی الگو از یک طبقه‌بند استفاده می‌شود که معمولاً با افراز فضای ویژگی، تصمیم‌سازی مناسب انجام می‌شود.

با پیچیده‌تر شدن فضای ویژگی (از نظر کمی و کیفی) از یک سو و افزایش کلاس‌ها و تداخل آن‌ها از سوی دیگر، طبقه‌بندهای معمولی از دقت کافی برخوردار نیستند. از این رو، از اوایل دهه ۹۰ میلادی، ایده استفاده از چند طبقه‌بند به جای یک طبقه‌بند مطرح شد [۱۳].

توضیح اینکه با توجه به عملکرد محدود طبقه‌بند واحد، این امکان وجود ندارد که بتوان با یک طبقه‌بند، در همه موارد به نتایج خوبی رسید؛ در هر مورد، انتخاب طبقه‌بند بهینه، شدیداً به حوزه مسئله وابسته است. در عمل، ممکن است به موردی برخورد کنید که در آن، هیچ طبقه‌بند مجزایی نمی‌تواند به سطح دقت قابل قبولی برسد حتی اگر تمام پارامترهای آن بهینه شده باشد؛ در اینگونه موارد، بهتر است نتایج طبقه‌بندهای مختلف را به اشتراک گذاشته شود تا به دقت بهینه برسید. هر طبقه‌بند، روی جنبه‌های مختلفی از بردار ویژگی آموزش یا آزمون، خوب عمل می‌کند، در نتیجه با فرض مساعد بودن شرایط، ترکیب چند طبقه‌بند در مقایسه با یک طبقه‌بند مجزا، باعث بهبود عملکرد طبقه‌بندی می‌شود [۱۴].

همان‌طور که قبلاً در مقدمه اشاره شد هدف روش OCS، پیدا کردن مناسب‌ترین زیرمجموعه از طبقه‌بندها ست. روش‌های مبتنی بر OCS، شامل دو مرحله می‌باشند: تولید اضافی و انتخاب. در مرحله اول، با استفاده از داده‌های آموزشی، مجموعه اولیه بزرگی از طبقه‌بندهای کاندید ساخته می‌شود. مرحله دوم به تشخیص بهترین زیرمجموعه از طبقه‌بندها می‌پردازد. سپس شورای انتخاب شده برای تخمین برچسب کلاس نمونه‌های آزمون باهم ترکیب می‌شوند.

به طور کلی، یک طبقه‌بند شورایی عبارت است از مجموعه‌ای از طبقه‌بندهای پایه که تصمیمات خود را به صورت مستقل و بر پایه تمام یا قسمتی از فضای ویژگی ارائه می‌کنند. تصمیم نهایی شورا در این طبقه‌بندها با ترکیب تصمیمات مستقل اتخاذ شده توسط طبقه‌بندهای پایه حاصل می‌شود. به عبارت دیگر، طراحی سامانه‌های طبقه‌بند شورایی بر ادغام چند طبقه‌بند با یک قاعده ترکیب استوار است.

یکی از نکات اساسی در موفقیت سامانه‌های طبقه‌بند شورایی، گوناگونی در خطا است. استفاده از طبقه‌بندهای پایه مختلف، رویکردی برای ایجاد شورایی از طبقه‌بندهای گوناگون است که این روش در مقاله حاضر، به کار گرفته شده است.

ایجاد امکان پدافند در برابر اهداف مانوری و بهبود سرعت تصمیم‌گیری، ساختاری کلی برای مانورهای مختلف اهداف در مختصات حرکتی ارائه کرده‌اند. به علاوه، خط سیر اهداف مختلف از دیدگاه رادار شبیه‌سازی شده و شناخت مانور در ردگیری مورد توجه قرار گرفته است. علی‌رغم اهمیت قابلیت اطمینان در سامانه‌های رادار، هیچ یک از تحقیقات فوق، این معیار را در نظر نگرفته‌اند.

در این مقاله، از دو الگوریتم ابتکاری چند هدفه برای انتخاب مناسب‌ترین زیرمجموعه طبقه‌بندها (از میان طبقه‌بندهای اولیه موجود در مخزن طبقه‌بندها) به منظور ساخت شورایی طبقه‌بندها استفاده می‌شود به نحوی که شورایی طبقه‌بند ایجاد شده، برای نخستین بار، ضمن برخورداری از کمترین سایز شورا و بیشترین نرخ تشخیص صحیح، از قابلیت اطمینان بالایی نیز برخوردار است. شایان ذکر است که تعیین ضرایب بهینه برای ادغام و ترکیب تصمیمات طبقه‌بندهای پایه نیز بر عهده همین الگوریتم‌های بهینه‌سازی چند هدفه مورد استفاده است؛ این دو الگوریتم عبارتند از روش بهینه‌سازی چند هدفه ازدحام ذرات (MOPSO) ۱ که دارای سابقه‌ای بیش از یک دهه در مواجهه با مسائل پیچیده چند هدفه بوده است و روشی مبتنی بر هوش جمعی است و الگوریتم دیگر روش بهینه‌سازی چند هدفه سامانه صفحات شیب‌دار است (MOIPO) ۲ که به تازگی گزارش شده [۱۲] و تاکنون در حوزه طراحی طبقه‌بندهای شورایی به کار گرفته نشده است. بنابراین، علاوه بر ارائه روشی برای افزایش قابلیت اطمینان تصمیم‌سازی هم‌زمان با بهینه‌سازی خطا و سایز شورا- در طبقه‌بندهای شورایی، وجه دیگر نوآوری این تحقیق به خدمت گرفتن روش جدید MOIPO در حوزه طراحی اینگونه طبقه‌بندها برای نخستین بار است.

در ادامه این مقاله، ابتدا مفهوم طبقه‌بندهای شورایی و مسئله انتخاب در این سامانه‌ها بررسی می‌شود، سپس الگوریتم‌های بهینه‌سازی مورد استفاده مرور می‌شوند. در بخش بعدی، نحوه انجام بهینه‌سازی توأمان معیارهای نرخ خطا، سایز شورا و قابلیت اطمینان توسط الگوریتم‌های ابتکاری چند هدفه بهینه‌سازی ازدحام ذرات و بهینه‌سازی سامانه صفحات شیب‌دار ارائه می‌شود، ضمن آنکه در این بخش، مسئله قابلیت اطمینان نیز به تفصیل شرح داده خواهد شد. در نهایت، نتایج و بحث و نتیجه‌گیری ارائه خواهد شد.

۲. روش تحقیق

طبقه‌بندهای شورایی: هدف یک سامانه بازنمایی الگو، قرار دادن الگوها با کمترین خطا در کلاس مربوط به خودشان است. به این

¹ Multi-Objective Particle Swarm Optimization

² Multi-Objective Inclined Planes Optimization

فاصله جبهه نامغلوب تا جبهه بهینه پرتو، باید به حداقل برسد.

راه‌حل‌های پیدا شده باید دارای توزیع مناسبی باشند.

گسترده‌گی جبهه نامغلوب نهایی، باید به حداکثر برسد؛ یعنی برای هر هدف، دامنه گسترده‌ای از مقادیر باید تحت پوشش راه‌حل‌های نامغلوب قرار گیرد.

با توجه نکات ذکر شده، در بهینه‌سازی چند هدفه باید به سه مسئله اساسی توجه کرد [۱۹]:

چگونگی تخصیص شایستگی و انتخاب، به منظور هدایت الگوریتم به سمت مجموعه بهینه پرتو.

چگونگی حفظ تنوع، به منظور جلوگیری از همگرایی زودرس و رسیدن به یک مجموعه نامغلوب با توزیع مناسب.

نخه‌گرایی؛ یعنی چگونگی جلوگیری از نابودی راه‌حل‌های نامغلوب.

در ادامه الگوریتم‌های ابتکاری چند هدفه مورد استفاده در این مقاله شرح داده می‌شوند.

الگوریتم بهینه‌سازی ازدحام ذرات چند هدفه (MOPSO): الگوریتم بهینه‌سازی ازدحام ذرات یکی از مهم‌ترین الگوریتم‌های بهینه‌سازی هوشمند است که در حوزه هوش ازدحامی جای می‌گیرد. این الگوریتم، توسط جیمز کندی و راسل سی ابرهات [۲۰] معرفی شد. این روش با الهام از رفتار اجتماعی حیواناتی چون ماهی‌ها و پرندگان که در گروه‌هایی کوچک و بزرگ کنار هم زندگی می‌کنند، طراحی شده است.

مبنای توسعه الگوریتم PSO این است که جواب‌های ممکن در یک مسئله بهینه‌سازی به صورت پرندگانی بدون حجم و خصوصیات کیفی در نظر گرفته می‌شوند که به آنان ذرات گفته می‌شود. این پرندگان در یک فضای N بعدی پرواز کرده و مسیر حرکت خود را در فضای جستجو بر اساس تجارب گذشته خود و همسایگان‌شان تغییر می‌دهند.

در دسته‌ای متشکل از N ذره، موقعیت ذره i ام تحت تأثیر یک بردار مکانی n بعدی مطابق معادله (۱) قرار دارد.

$$\vec{x}_i = (x_{i1}, x_{i2}, \dots, x_{in}) \in S \quad (1)$$

که در آن، S فضای جستجو است.

بردار سرعت این ذره به صورت معادله (۲) است.

$$v_i = (v_{i1}, v_{i2}, \dots, v_{in}) \quad (2)$$

در مقابل بهینه‌سازی پوشش (ساخت مجموعه‌ای دقیق و گوناگون از طبقه‌بندها)، بهینه‌سازی تصمیم نیز از اهمیت به سزایی برخوردار است؛ بنا به تعریف، با فرض وجود مجموعه‌ای ثابت از طبقه‌بندهای به دقت طراحی شده، بهینه‌سازی تصمیم به دنبال قاعده ترکیب بهینه‌ای است که تصمیم‌های مجموعه طبقه‌بندها را ادغام کند. در این مقاله، روش مورد استفاده برای ترکیب نتایج طبقه‌بندها، روش رأی‌گیری وزن‌دار است که وزن هر طبقه‌بند توسط الگوریتم‌های ابتکاری چند هدفه (MOIPO و MOPSO) با بهینه‌سازی هم‌زمان نرخ خطا، سائز شورا و قابلیت اطمینان مشخص می‌گردد.

الگوریتم‌های ابتکاری چند هدفه: الگوریتم ابتکاری روشی است که در آن سرعت فرآیند به اندازه کیفیت جواب به‌دست آمده برای یک مسئله بهینه‌سازی، مهم است؛ زمان صرف شده در الگوریتم ابتکاری برای یافتن پاسخ بهینه مربوط به یک مسئله پیچیده در مقایسه با زمانی که یک روش دقیق (به شرط وجود چنین روشی) نیاز دارد، بسیار کمتر خواهد بود [۱۵]. به بیان دقیق‌تر، روش ابتکاری یک راهبرد است که قسمتی از اطلاعات را به منظور تصمیم‌گیری سریع، با حداکثر صرفه‌جویی در زمان و با بیشترین دقت، نسبت به روش‌های پیچیده نادیده می‌گیرد [۱۶].

در الگوریتم‌های ابتکاری، جستجو به صورت موازی صورت می‌گیرد؛ یعنی مجموعه‌ای از عامل‌ها، فضای مسئله را جستجو می‌کنند. به همین دلیل، توانایی یافتن راه‌حل‌های بهینه پرتو را با یک بار اجرای الگوریتم دارند. اکثر این روش‌ها به صورت جمعیتی عمل کرده و برای هدایت جستجو از تابع برازندگی استفاده می‌کنند. این الگوریتم‌ها می‌توانند هم در زمان صرفه‌جویی کنند و هم با استفاده از تدابیری خاص از بهینه‌های محلی بگریزند و به بهینه سراسری همگرا شوند. از آنجا که الگوریتم‌های ابتکاری با رویکرد موازی به حل مسائل می‌پردازند، همواره مجموعه‌ای از پاسخ‌ها را ایجاد می‌کنند و ابزاری مناسب برای حل مسائل چند هدفه به شمار می‌روند. مهم‌ترین مزیت استفاده از الگوریتم‌های ابتکاری، انعطاف‌پذیری، سازگاری بالا، سرعت و کارایی زیاد و ویژگی جستجوی سراسری آن‌هاست [۱۷].

در بهینه‌سازی تک هدفه، معمولاً پاسخ بهینه به وضوح، قابل بیان است اما در بهینه‌سازی چند هدفه نمی‌توان تنها یک راه‌حل را به عنوان بهترین جواب مسئله معرفی کرد. در اینگونه مسائل باید مجموعه‌ای از راه‌حل‌ها را (که هر یک از اهداف را در سطح قابل قبولی برآورده می‌سازند) به عنوان مجموعه جواب بهینه معرفی کرد. به طور کلی در بهینه‌سازی چند هدفه باید نکات زیر مدنظر قرار گیرد [۱۸]:

بهترین موقعیت قبلی به دست آمده برای ذره t ام، با استفاده از معادله (۳) نمایش داده می‌شود.

بهترین موقعیت قبلی به دست آمده برای ذره t ام، با استفاده از معادله (۳) نمایش داده می‌شود.

$$p_i = (p_{i1}, p_{i2}, \dots, p_{in}) \quad (3)$$

الف- اگر موقعیت جدید، بهترین خاطره را مغلوب کند، آنگاه موقعیت جدید جایگزین بهترین خاطره می‌شود.

موقعیت جدید ذرات هم با استفاده از معادلات (۴ و ۵) به دست می‌آید.

ب- اگر موقعیت جدید توسط بهترین خاطره مغلوب شود، بهترین خاطره بدون تغییر باقی می‌ماند.

$$v_i(t+1) = \omega v_i(t) + c_1 r_1 (p_i(t) - x_i(t)) \quad (4)$$

ج- اگر هیچ کدام همدیگر را مغلوب نکنند، به تصادف یکی از آن‌ها به عنوان بهترین خاطره در نظر گرفته می‌شود.

$$+ c_2 r_2 (p_g(t) - x_i(t))$$

اعضای نامغلوب جمعیت فعلی به آرشیو اضافه می‌شوند.

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (5)$$

اعضای مغلوب آرشیو حذف می‌شوند.

اگر تعداد اعضای آرشیو بیش از ظرفیت تعیین شده باشد، اعضای اضافی حذف می‌شوند.

در این معادلات:

در صورتی که شرایط خاتمه محقق شده باشد، پایان و در غیر این صورت به مرحله ۳ برمی‌گردد.

ω : ضریب اینرسی.

g : شاخص به کار رفته برای ذره‌ای که بهترین موقعیت را دارد.

الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار چند هدفه

t : نشان‌دهنده تعداد تکرار.

(MOIPO): الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار، از نحوه

C_1 : ضریب یادگیری شخصی.

حرکت دینامیکی اجسام کروی بر روی سطح شیب‌دار بدون

C_2 : ضریب یادگیری جمعی.

اصطکاک الهام گرفته است که همگی تمایل دارند به پایین‌ترین

r_1 و r_2 : اعداد تصادفی در بازه [۰، ۱].

نقطه سطح برسند. در این الگوریتم، عوامل الگوریتم (تعدادی توپ

سرعت هر یک از ذرات دارای مقدار حداکثری است که توسط کاربر تعیین می‌شود.

کوچک) فضای جستجو را برای یافتن نقطه بهینه جستجو

می‌کنند. ایده اصلی این الگوریتم نسبت دادن ارتفاع با توجه به

یک نقطه مرجع به هر توپ است که میزان این ارتفاع بر اساس

تابع برازندگی به دست می‌آید. این مقادیر ارتفاع، در واقع تخمینی

از انرژی پتانسیل توپ‌هایی هستند که در ارتفاعات مختلف قرار

دارند و با پایین آمدن آن‌ها، این انرژی به انرژی جنبشی تبدیل

شده و باعث شتاب گرفتن توپ‌ها به سمت پایین می‌شود؛ در واقع

توپ‌ها تمایل دارند تا انرژی پتانسیل خود را برای رسیدن به نقطه

کمینه از دست بدهند. بنابراین توپ‌ها به صورت مکرر بر روی

فضای جستجو برای یافتن پاسخ بهتر حرکت کرده و به تناسب،

شتابی را به خود اختصاص می‌دهند.

برای به کارگیری الگوریتم ازدحام ذرات در حل مسائل

بهینه‌سازی چند هدفه می‌بایست ساختار اصلی الگوریتم را اصلاح

نمود؛ در این حالت، مفهوم بهترین ذره برخلاف حالت تک هدفه

ثابت نیست بلکه هر یک از ذره‌ها در هر لحظه، به طور تصادفی

یکی از اعضای آرشیو (پاسخ‌های نامغلوب) را به عنوان رهبر

انتخاب می‌کنند. یکی از معروف‌ترین و کارآمدترین پیشنهادهای

ارائه شده برای الگوریتم بهینه‌سازی ازدحام ذرات چند هدفه

(MOPSO) شامل مراحل زیر است [۲۱]:

هر توپ در فضای جستجو دارای سه ویژگی است: موقعیت،

ایجاد جمعیت اولیه و ارزیابی آن.

ارتفاع و زاویه‌هایی که با دیگر توپ‌ها می‌سازد. موقعیت هر توپ

جدا کردن اعضای نامغلوب جمعیت و ذخیره کردن آن‌ها در

یک جواب ممکن در فضای جستجو است و ارتفاع آن به وسیله

آرشیو.

تابع برازندگی به دست می‌آید. برای داشتن تخمینی از صفحه

جدول بندی فضای هدف کشف شده.

شیب‌داری که توپ‌ها بر روی آن قرار دارند از خطوطی مستقیم

استفاده شده که مراکز توپ‌ها را به هم وصل می‌کنند. این خطوط

هر ذره از میان اعضای آرشیو، یک رهبر انتخاب می‌کند و حرکت

با خط راست افقی عبوری از مرکز توپ، زاویه‌ای را تشکیل

خود را بر اساس معادلات (۴) و (۵) انجام می‌دهد. (رهبر انتخاب

می‌دهد که به وسیله آن جهت و میزان شتاب اختصاص یافته به

شده همان p_g در معادله (۴) است).

$rand_1$ و $rand_2$ دو ثابت تصادفی هستند که به صورت یکنواخت در بازه $[0, 1]$ توزیع شده‌اند تا به الگوریتم IPO ماهیت تصادفی داده شود. $v_i^d(t)$ سرعت توپ i ام در بعد d ام و در زمان t ام است. برای کنترل فرآیند جستجوی الگوریتم از دو پارامتر k_1 و k_2 استفاده شده است. $v_i^d(t)$ به صورت معادله (۱۰) محاسبه می‌گردد.

$$v_i^d(t) = \frac{x_{best}^d(t) - x_i^d(t)}{\Delta t} \quad (10)$$

در محاسبه سرعت در معادله (۱۰)، در صورت کسر از مقدار x_{best} استفاده شده است تا بتوان میل رسیدن توپ، به بهترین مکان مجموعه توپ‌ها در هر تکرار را مدل‌سازی کرد [۲۲].

مشابه آنچه برای الگوریتم بهینه‌سازی ازدحام ذرات گفته شد در اینجا نیز می‌توان با اعمال تغییراتی، به نسخه چند هدفه الگوریتم رسید. مراحل الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار چند هدفه مانند مراحل الگوریتم بهینه‌سازی ازدحام ذرات چند هدفه است با ذکر این نکته که در مرحله چهارم، رهبر انتخاب شده، x_{best}^d در معادله (۱۰) است. تفاوت مهم روش MOIPO با MOPSO در سازوکار جستجوی فضای پاسخ و معادلات مورد استفاده است.


نحوه استفاده از الگوریتم‌های ابتکاری چند هدفه جهت بهینه‌سازی انتخاب طبقه‌بندها: هدف این مقاله، بهینه‌سازی مرحله انتخاب در روش OCS است. در مرحله انتخاب، تعدادی از طبقه‌بندهای موجود در مخزن اولیه به منظور ساخت شورا انتخاب می‌شوند که عمل بهینه‌سازی به دنبال انتخاب بهترین زیرمجموعه از طبقه‌بندها است. ارزیابی عملکرد طبقه‌بند شورایی ایجاد شده با استفاده از معیار مهم قابلیت اطمینان در کنار معیارهای مرسوم چون نرخ خطا و سائز شورا انجام می‌شود.

مخزن اولیه طبقه‌بندها شامل سه نوع طبقه‌بند است: ۱۰ طبقه‌بند شبکه عصبی پرسپترون چندلایه با تعداد لایه‌های پنهان متفاوت، ۵ طبقه‌بند K- نزدیک‌ترین همسایه با Kهای مختلف و ۵ طبقه‌بند بیز با توزیع‌های متفاوت. بدیهی است می‌توان به تنوع و تعدد مخزن شورا را به دلخواه تغییر داد.

هنگام استفاده از الگوریتم‌های ابتکاری جهت انجام بهینه‌سازی توجه به دو مسئله مهم حائز اهمیت است: نحوه بیان عوامل جستجو و تابع برازندگی. این دو موضوع در زیر توضیح داده می‌شوند.

تعریف عوامل جستجو: ابعاد عوامل جستجو در هر یک از الگوریتم‌های مورد استفاده دو برابر سائز مخزن اولیه طبقه‌بندها است. با توجه به اینکه مخزن اولیه شامل ۲۰ طبقه‌بند است، ابعاد در نظر گرفته شده برای عوامل جستجو ۴۰ خواهد بود. ۲۰ بعد

هر توپ تعیین می‌شود. یک سامانه فرضی در شکل (۱) نشان داده شده است.



شکل ۱. یک مثال از فضای جستجو با سه توپ و تخمینی از صفحه شیب‌دار [۲۲]

سامانه‌ای متشکل از N توپ را در نظر بگیرید. موقعیت توپ i ام به وسیله معادله (۶) تعریف می‌شود:

$$\bar{x}_i = (x_i^1, \dots, x_i^d, \dots, x_i^n), \quad \text{for } i = 1, 2, \dots, N \quad (6)$$

$$x_j^{\min} \leq x_j \leq x_j^{\max}, \quad 1 \leq j \leq n$$

به طوری که x_i^d موقعیت توپ i ام در بعد d ام در فضای n بعدی است.

در یک زمان مشخص مانند t ، زاویه بین توپ i ام و توپ j ام در بعد d ، یعنی ϕ_{ij}^d با استفاده از معادله (۷) محاسبه می‌شود:

$$\phi_{ij}^d(t) = \left[\tan^{-1} \left(\frac{f_j(t) - f_i(t)}{x_i^d(t) - x_j^d(t)} \right) \right] \quad (7)$$

for $d = 1, \dots, n$ and $i, j = 1, 2, \dots, N, i \neq j$

به گونه‌ای که $f_i(t)$ مقدار تابع هدف (ارتفاع) برای توپ i ام در زمان t است. به دلیل اینکه یک توپ مشخص باید به سمت پایین‌ترین ارتفاع بر روی صفحه شیب‌دار حرکت کند، تنها توپ‌هایی که در ارتفاع (برازندگی) پایین‌تر قرار دارند، در محاسبات شتاب، به کار گرفته می‌شوند.

مقدار و جهت شتاب برای توپ i ام در زمان (تکرار) t ام در بعد d ام از رابطه (۸) به دست می‌آید.


$$a_i^d(t) = \sum_{j=1}^N U(f_j(t) - f_i(t)) \cdot \sin(\phi_{ij}^d(t)) \quad (8)$$

که در آن، $U(\cdot)$ تابع پله واحد است.

در نهایت از معادله (۹) برای به‌روزرسانی موقعیت توپ‌ها استفاده می‌شود:

$$x_i^d(t+1) = k_1 \cdot rand_1 \cdot a_i^d(t) \cdot \Delta t^2 + k_2 \cdot rand_2 \cdot v_i^d(t) \cdot \Delta t + x_i^d(t) \quad (9)$$

است. شایان ذکر است که بسیار اتفاق می‌افتد یک طبقه‌بند، توانایی تشخیص صحیح همه الگوهای آموزشی یک کلاس خاص را دارد ولی به علت ورود الگوهایی از کلاس‌های دیگر به ناحیه کلاس مورد نظر، قابلیت اطمینان تصمیم گرفته شده، کاهش می‌یابد. شکل (۲)، دو کلاس متفاوت را نشان می‌دهد که نمونه‌های آن‌ها در فضای ویژگی دوبعدی با توپ‌های سفید و سیاه از یکدیگر متمایز شده‌اند. تابع تصمیم $d(x)$ یکی از الگوهای کلاس سیاه را به کلاس سفید نسبت داده است. بنابراین نرخ تشخیص صحیح توپ‌های سیاه به وسیله این تابع تصمیم برابر با ۸۰ درصد است در حالی که قابلیت اطمینان کلاس سیاه ۱۰۰ درصد است. از طرف دیگر، اگر چه نرخ تشخیص صحیح الگوهای سفید با تابع تصمیم مفروض، ۱۰۰ درصد است اما قابلیت اطمینان به تصمیم این طبقه‌بند در خصوص تعلق یک الگو به کلاس سفید معادل ۸۳ درصد است.



شکل ۲. نرخ تشخیص صحیح کلاس سیاه ۸۰٪، قابلیت اطمینان آن ۱۰۰٪، نرخ تشخیص صحیح کلاس سفید ۱۰۰٪ و قابلیت اطمینان آن ۸۳٪ است.

قابلیت اطمینان مربوط به هر کلاس از رابطه (۱۲) به دست می‌آید که در آن T_i تعداد نمونه‌های کلاس نام است که توسط طبقه‌بند درست طبقه‌بندی شده‌اند و T تعداد کل نمونه‌هایی است که در ناحیه متعلق به این کلاس قرار گرفته‌اند و R_i قابلیت اطمینان کلاس نام است [۲۴]:

$$R_i = \frac{T_i}{T} \quad (12)$$

حاصل ضرب قابلیت‌های اطمینان هر کلاس، تابع برازندگی مناسبی است که می‌توان برای رسیدن به بیشترین قابلیت اطمینان در طبقه‌بندهای شورایی در نظر گرفت. از آنجایی که در این تحقیق، دو تابع هدف دیگر طوری تعریف شده‌اند که طی فرآیند بهینه‌سازی، کمینه می‌شوند، عکس حاصل ضرب ذکر شده به عنوان تابع هدف سوم لحاظ می‌شود و با کمینه کردن آن، قابلیت اطمینان به بیشترین مقدار خود خواهد رسید.

اول در عوامل به صورت باینری کد می‌شوند که در آن‌ها یک به معنای انتخاب طبقه‌بند و صفر به معنای عدم انتخاب است. ۲۰ بعد دیگر، ضرایب مربوط به هر طبقه‌بند را نشان می‌دهد که از این ضرایب در مرحله ترکیب طبقه‌بندها استفاده می‌شود.

بنابراین عامل نام به صورت معادله (۱۱) مشخص می‌شود که یک بردار با سایز ۴۰ است و A_{i1} تا A_{i20} اعداد باینری برای انتخاب طبقه‌بندها می‌باشند و A_{i21} تا A_{i40} ضرایب مربوط به هر طبقه‌بند را شامل می‌شوند.

$$A_i = (A_{i1}, A_{i2}, \dots, A_{i40}) \quad (11)$$

تعریف تابع برازندگی: همان‌طور که اشاره شد، تابع برازندگی مسئله مهمی است که باید به طور مناسبی تعریف شود. در واقع ارزیابی هر یک از اعضای جمعیت از طریق محاسبه مقدار تابع هدف (برازندگی) انجام می‌شود. در این مقاله سه تابع هدف در نظر گرفته شده عبارتند از: سایز شورا، نرخ خطا و قابلیت اطمینان؛ انتظار می‌رود که با استفاده از الگوریتم‌های ابتکاری چند هدفه، این توابع بهینه شوند.

الف- سایز شورا: اغلب روش‌های موجود در یادگیری شورایی، تمام طبقه‌بندهای تشکیل دهنده شورا را به کار می‌گیرند که در بعضی موارد سایز شورا بیش از حد بزرگ می‌شود و منجر به زمان محاسبات و هزینه بیشتر می‌شود [۲۳]. یکی از توابع هدف این مقاله، سایز شورا است که انتظار می‌رود با به کارگیری الگوریتم‌های بهینه‌سازی چند هدفه، سایز شورا کمینه گردد.

ب- نرخ خطا: تابع هدف دیگری که در این تحقیق در نظر گرفته شده، نرخ خطای طبقه‌بندی است. در واقع با کمینه کردن نرخ خطا، نرخ تشخیص صحیح بیشینه می‌گردد.

ج- قابلیت اطمینان: سایز شورا و نرخ خطا توابع هدفی هستند که در اغلب موارد، مبنای ارزیابی عملکرد طبقه‌بندهای شورایی در نظر گرفته می‌شوند. این در حالی است که معیارهای مهم دیگری نیز وجود دارند و می‌توانند ملاکی برای ارزیابی عملکرد طبقه‌بندهای شورایی باشند و چه بسا اهمیت این معیارها بیشتر از معیارهای مرسوم باشد، به عنوان مثال بارزی از این نمونه معیارها می‌توان به قابلیت اطمینان اشاره کرد. قابلیت اطمینان روی یک کلاس خاص یعنی چه تعداد از الگوهایی که برچسب یک کلاس خاص را خورده‌اند واقعاً متعلق به آن کلاس هستند. قابلیت اطمینان یکی از معیارهای مهم در ارزیابی عملکرد طبقه‌بندهای شورایی است که کمتر به آن پرداخته شده است این در حالی است که در برخی طبقه‌بندها، معیار قابلیت اطمینان نسبت به نرخ تشخیص صحیح از اهمیت بیشتری برخوردار است. به عنوان مثال، در یک سامانه بازشناسی خودکار هدف، اطمینان بالا به تصمیم نهایی یک طبقه‌بند، از میزان خطای آن مهم‌تر

ضریب یادگیری شخصی: ۱

ضریب یادگیری جمعی: ۲

جمعیت: ۲۰

تعداد تکرارها: ۲۰۰

ضریب اینرسی اولیه: ۰/۵

ضریب کاهش اینرسی: ۰/۹۹

در الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار، پارامترها و متغیرها عبارتند از:

جمعیت: ۲۰

تعداد تکرارها: ۲۰۰

C_1 : ۰/۷۱۸۴

C_2 : ۲/۷۶۱۳

$shift_1$: ۷۲/۴۶۸۴

$shift_2$: ۱۸۸/۵۰۷۷

$scale_1$: ۰/۰۳۵

$scale_2$: ۰/۸۲۴۵

این پارامترها برای محاسبه مقادیر $k_1(t)$ و $k_2(t)$ به کار می‌روند که از معادله‌های (۱۳) و (۱۴) محاسبه می‌شوند.

$$k_1(t) = \frac{c_1}{1 + \exp((t - shift_1) \times scale_1)} \quad (13)$$

$$k_2(t) = \frac{c_2}{1 + \exp((t - shift_2) \times scale_2)} \quad (14)$$

نتایج حاصل در جداول (۱-۴) خلاصه شده‌اند. جدول (۱) بهترین میانگین هر یک از توابع هدف را برای مجموعه داده‌های آزمون در بین ده بار اجرای الگوریتم‌ها نشان می‌دهد.

جدول ۱. نتایج مقایسه‌ای به‌دست آمده با استفاده از الگوریتم ازدحام ذرات چند هدفه و الگوریتم سامانه صفحات شیب‌دار چند هدفه

داده	الگوریتم	سایز شورا	نرخ خطا	معکوس حاصل ضرب قابلیت اطمینان کلاس‌ها
Iris	MOPSO	۶/۵	۰/۰۳۳۳	10^{-6} ۱/۱۰۵۲*
	MOIPO	۳	۰/۰۱۳۳	10^{-6} ۱/۰۴۰۰*
Wine	MOPSO	۶/۴۲	۰/۰۵۸۸	10^{-6} ۱/۳۲۰۰*
	MOIPO	۵/۲	۰/۰۱۳۶	10^{-6} ۱/۰۳۶۹*
Glass	MOPSO	۵/۵	۰/۱۱۳۲	10^{-4} ۱/۴۸۰۰*
	MOIPO	۳	۰/۰۸۴۹	10^{-4} ۱/۳۶۰۰*
Ovarian	MOPSO	۵/۷	۰/۰۳۹۴	10^{-4} ۱/۰۸۶۵*
	MOIPO	۳/۵	۰/۰۲۷۸	10^{-4} ۱/۰۶۱۲*

روش ترکیب: در قسمت‌های قبل، نحوه بیان عوامل جستجو و توابع برازندگی بررسی شد. پس از پیدا کردن زیرمجموعه طبقه‌بندها باید روشی برای ترکیب این طبقه‌بندها در نظر گرفت؛ روش رأی‌گیری وزن‌دار یکی از قوانین ترکیب در طبقه‌بندهای شورایی به شمار می‌رود که در این تحقیق از آن استفاده شده است و وزن مربوط به هر طبقه‌بند توسط عامل جستجو مشخص می‌شود. در صورتی که یک طبقه‌بند انتخاب شده باشد با ضریب مربوطه وارد ترکیب می‌شود. برای مثال در طبقه‌بندی نمونه‌هایی که شامل دو کلاس هستند، ضرایب مربوط به طبقه‌بندهایی که یک نمونه را به کلاس اول نسبت داده‌اند باهم جمع می‌شود و ضرایب مربوط به طبقه‌بندهایی که نمونه را به کلاس دوم نسبت داده‌اند نیز باهم جمع می‌شود، سپس کلاس نهایی نمونه، کلاسی است که بیشترین مجموع را به‌دست آورده است.

۳. نتایج و بحث

به منظور ارزیابی کارآمدی هر یک از الگوریتم‌های مذکور در روند انتخاب بهینه طبقه‌بندها از چهار مجموعه داده موجود در UCI استفاده شده است. این مجموعه‌ها عبارتند از:

مجموعه داده Iris: شامل ۱۵۰ نمونه، ۴ ویژگی و سه کلاس مرجع.

مجموعه داده Glass: شامل ۲۱۴ نمونه، ۹ ویژگی و دو کلاس مرجع.

مجموعه داده Wine: شامل ۱۷۸ نمونه، ۱۳ ویژگی و سه کلاس مرجع.

مجموعه داده Ovarian: شامل ۲۱۶ نمونه، ۱۰۰ ویژگی و دو کلاس مرجع.

پارامترها و متغیرهای الگوریتم بهینه‌سازی ازدحام ذرات چند هدفه به صورت زیر در نظر گرفته شده‌اند:

نتایج مربوط به مجموعه داده Ovarian نیز تقریباً مشابه مجموعه داده Glass است. بنابراین همان‌طور که نتایج شبیه‌سازی نشان می‌دهد الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار چند هدفه که تاکنون در هیچ وجهی از طراحی طبقه‌بندی‌های شورایی به کار گرفته نشده است، در اکثر موارد منجر به نتایج بهتری شده است که این بهبود در برخی از توابع هدف نسبت به نتایج الگوریتم بهینه‌سازی ازدحام ذرات چشمگیر بوده است. با توجه به اینکه تابع هدف تعریف شده برای قابلیت اطمینان به صورت حاصل ضرب قابلیت‌های اطمینان به‌دست آمده برای هر یک از کلاس‌های مرجع است، برای برداشت بهتر و شفاف‌تر از عملکرد روش‌های پیشنهادی و مقایسه آن‌ها، میانگین قابلیت اطمینان هر کلاس در جدول (۲) گزارش شده است.

با توجه به جدول (۱)، در مجموعه داده Iris، عملکرد الگوریتم سامانه صفحات شیب‌دار چند هدفه بهتر بوده و برای سایز شورا، نرخ خطا و قابلیت اطمینان به ترتیب $۵۳/۸$ ، $۶۰/۱$ و ۶ درصد بهبود مشاهده می‌شود. در مورد مجموعه داده Wine، الگوریتم سامانه صفحات شیب‌دار چند هدفه منجر به بهبود $۲۱/۵$ ، $۷۶/۹$ و ۱۹ درصدی مقادیر میانگین گزارش شده تابع هدف تعریف شده برای قابلیت اطمینان، نرخ خطا و سایز شورا شده است. نتایج به‌دست آمده برای مجموعه داده Glass، همچنان برتری الگوریتم سامانه صفحات شیب‌دار چند هدفه را نسبت به الگوریتم ازدحام ذرات چند هدفه نشان می‌دهد. در این وضعیت تابع هدف تعریف شده برای معیار قابلیت اطمینان $۸/۱$ درصد بهبود داشته ضمن آنکه سایز شورا و نرخ خطا به میزان $۴۵/۵$ و ۲۵ درصد تغییر کرده است.

جدول ۲. قابلیت اطمینان به‌دست آمده به تفکیک هر کلاس

داده	الگوریتم	قابلیت اطمینان کلاس اول	قابلیت اطمینان کلاس دوم	قابلیت اطمینان کلاس سوم
Iris	MOPSO	۱۰۰	۹۶/۱۵	۹۴/۲۱
	MOIPO	۱۰۰	۱۰۰	۹۶/۱۵
Wine	MOPSO	۹۸/۷۲	۹۲/۶۵	۹۱/۴۲
	MOIPO	۱۰۰	۹۷/۲۵	۹۹/۲۰
Glass	MOPSO	۱۰۰	۶۷/۶۲	-
	MOIPO	۱۰۰	۷۳/۵۳	-
Ovarian	MOPSO	۹۷/۵۲	۹۴/۵۵	-
	MOIPO	۹۸/۳۳	۹۵/۸۷	-

تابع هدف نرخ خطا و سایز شورا (مطابق آنچه در تحقیقات مرتبط قبل تعریف شده) انجام داده و سپس قابلیت اطمینان شوراهای ساخته شده محاسبه می‌شود و در نهایت، نتایج به‌دست آمده با حالتی که قابلیت اطمینان به عنوان تابع هدف لحاظ شده است و از این طریق بهینه می‌شود، مقایسه می‌گردد. نتایج به‌دست آمده در جدول‌های (۳) و (۴) گزارش شده‌اند.

جدول (۳) مقادیر قابلیت اطمینان هر کلاس، نرخ خطا و سایز شورا را در دو حالت (دو تابع هدف و سه تابع هدف) با استفاده از الگوریتم ازدحام ذرات چند هدفه برای داده‌های آزمون نشان می‌دهد. برای مجموعه داده Iris و Wine، هنگام استفاده از سه تابع هدف، قابلیت اطمینان به‌دست آمده برای هر کلاس به مراتب بالاتر از مقادیر به‌دست آمده با حالت دو تابع هدف است ضمن آنکه نرخ خطا نیز در این حالت بهبود داشته است. البته لازم به ذکر است که قابلیت اطمینان کلاس اول در مجموعه داده Iris، برای هر دو حالت ۱۰۰ درصد است.

در مجموعه داده Glass، باز هم علی‌رغم اینکه در حالت وجود دو تابع، سایز شورا بهبود داشته ولی قابلیت اطمینان کلاس دوم و

با توجه به جدول (۲)، برای مجموعه داده Iris، قابلیت اطمینان کلاس اول برای هر دو الگوریتم ۱۰۰ درصد است ولی برای کلاس دوم و سوم، الگوریتم MOIPO منجر به بهبود $۳/۸$ و ۲ درصدی قابلیت اطمینان شده است. در مجموعه داده Wine، قابلیت اطمینان به‌دست آمده توسط الگوریتم سامانه صفحات شیب‌دار چند هدفه روی همه کلاس‌ها نسبت به الگوریتم ازدحام ذرات چند هدفه بیشتر است؛ مقادیر بهبود در کلاس‌های اول، دوم و سوم به ترتیب عبارت است از: $۱/۳$ ، $۴/۷$ و $۷/۸$ درصد.

در مورد مجموعه داده Glass، مقدار قابلیت اطمینان کلاس اول در هر دو الگوریتم یکسان است اما برای کلاس دوم، بهبود ۸ درصدی توسط الگوریتم MOIPO مشاهده می‌شود. برای مجموعه داده Ovarian، الگوریتم سامانه صفحات شیب‌دار چند هدفه موجب بهبود در میزان قابلیت اطمینان هر دو کلاس شده است. اکنون که برتری عملکرد الگوریتم سامانه صفحات شیب‌دار چند هدفه در افزایش قابلیت اطمینان مشخص شده، نوبت آن رسیده تا به بررسی حالتی پرداخته شود که قابلیت اطمینان در توابع هدف در نظر گرفته نمی‌شود. به این منظور شبیه‌سازی‌ها را با دو

نرخ خطا و قابلیت اطمینان هر کلاس مشاهده می‌گردد. در جدول (۴) نتایجی مشابه با نتایج جدول (۳) ولی برای الگوریتم سامانه صفحات شیب‌دار چند هدفه گزارش شده است.

نرخ خطا در حالت سه تابع هدف بهتر شده این در حالی است که قابلیت اطمینان کلاس اول در هر دو حالت یکسان است. در مورد مجموعه داده Ovarian، بهبود در تمام مقادیر اعم از سایز شورا،

جدول ۳. قابلیت اطمینان به تفکیک هر کلاس، سایز شورا و نرخ خطا با استفاده از الگوریتم ازدحام ذرات چند هدفه

داده	تعداد توابع هدف	سایز شورا	نرخ خطا	قابلیت اطمینان کلاس اول	قابلیت اطمینان کلاس دوم	قابلیت اطمینان کلاس سوم
Iris	۲	۴/۶۶	۰/۰۴	۱۰۰	۹۵/۳۰	۹۴/۱۳
	۳	۶/۵	۰/۰۳	۱۰۰	۹۶/۱۵	۹۴/۲۱
Wine	۲	۳/۸	۰/۰۷	۹۸/۴۶	۹۲/۶۱	۸۹/۳۰
	۳	۶/۴۲	۰/۰۶	۹۸/۷۲	۹۲/۶۵	۹۱/۴۲
Glass	۲	۴/۶۶	۰/۱۳	۱۰۰	۶۵/۳۷	-
	۳	۵/۵	۰/۱۱	۱۰۰	۶۷/۶۲	-
Ovarian	۲	۷/۷۵	۰/۰۵	۹۶/۶۵	۹۲/۳۰	-
	۳	۵/۷	۰/۰۴	۹۷/۵۲	۹۴/۵۵	-

جدول ۴. قابلیت اطمینان به تفکیک هر کلاس، سایز شورا و نرخ خطا با استفاده از الگوریتم سامانه صفحات شیب‌دار چند هدفه

داده	تعداد توابع هدف	سایز شورا	نرخ خطا	قابلیت اطمینان کلاس اول	قابلیت اطمینان کلاس دوم	قابلیت اطمینان کلاس سوم
Iris	۲	۳/۴	۰/۰۳	۱۰۰	۹۵/۹۰	۹۳/۷۸
	۳	۳	۰/۰۱	۱۰۰	۱۰۰	۹۶/۱۵
Wine	۲	۳	۰/۰۲	۱۰۰	۹۷/۱۴	۹۶
	۳	۵/۲	۰/۰۱	۱۰۰	۹۷/۲۵	۹۹/۲۰
Glass	۲	۴	۰/۱۲	۱۰۰	۶۶/۰۷	-
	۳	۳	۰/۰۸	۱۰۰	۷۳/۵۳	-
Ovarian	۲	۳/۲۵	۰/۰۵	۹۵/۷۵	۹۴/۴۷	-
	۳	۳/۵	۰/۰۳	۹۸/۳۳	۹۵/۸۷	-

۴. نتیجه‌گیری

در این مقاله، از الگوریتم‌های بهینه‌سازی چند هدفه ابتکاری برای انتخاب زیرمجموعه بهینه طبقه‌بندها در فرآیند طراحی شورای طبقه‌بندها استفاده شده است. یکی از جنبه‌های نوآوری این مقاله، استفاده از الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار چند هدفه به عنوان یک الگوریتم نوین در روند انتخاب زیرمجموعه بهینه طبقه‌بندها است. دیگر جنبه نوآوری این طرح آن است که در کنار معیارهای سایز شورا و نرخ خطا، برای اولین بار از معیار مهم قابلیت اطمینان نیز برای طراحی و ارزیابی طبقه‌بند شورایی استفاده شده است. ویژگی این معیار از آن جهت است که در عمل ممکن است مواردی وجود داشته باشد که در

با توجه به جدول (۴)، برای مجموعه داده Iris، حالت سه تابع هدف منجر به بهبود تمامی مقادیر شده جز آنکه قابلیت اطمینان کلاس اول برای هر دو حالت ۱۰۰ درصد است. برای مجموعه داده Wine، باز هم قابلیت اطمینان در حالت سه تابع هدف بیشتر گزارش شده و نرخ خطا نیز بهبود یافته است. نتایج مربوط به مجموعه داده Glass، نشان‌دهنده برتری استفاده از سه تابع هدف به جای دو تابع هدف است چرا که علاوه بر بهبود مقادیر قابلیت اطمینان، مقادیر سایز شورا و نرخ خطا نیز بهبود پیدا کرده‌اند. برای مجموعه داده Ovarian، به غیر از سایز شورا تمامی مقادیر در حالت سه تابع هدف به مقادیر بهتری نسبت به حالت دو تابع هدف رسیده‌اند.

- [9] Mohanna, S.; Kalantari, L. S.; Tavakoli, S. "Design and Simulation of a Multistatic Radar System and Optimizing the Radar Sites Positions Using Multiobjective Genetic Algorithms"; *J. Adv. Defence Sci. & Tech.* 2011, 2, 241-247.
- [10] Naseri, A.; Saadatati Moghadam, G. "The Proposed Intelligent Algorithm for Process Section in the Radar Interception Systems"; *J. Adv. Defence Sci. & Tech.* 2011, 1, 87-98.
- [11] Alaei, M.; Amiri, R.; Keyvanshokoh, R.; Mahdlo, A. "Trajectory Determination of RADAR Targets"; *J. Adv. Defence Sci & Tech.* 2011, 2, 125-132.
- [12] Sayadi, N.; Zahiri, S. H. "MOIPO: A New Method for Multi-Objective Optimization in IT"; *National Conf. on Computer Engineering and IT Management*, 2014 (In Persian).
- [13] Nabavi, S. H. "Classifier Combination with Emphasis on Their Diversity"; Ph.D. Thesis, Tarbiat Modares University, Tehran, 2006 (In Persian).
- [14] Minaei-Bidgoli, B.; Kortemeyer, G.; Punch, W. F. "Optimizing Classification Ensembles via a Genetic Algorithm for a Web-Based Educational System"; *Proc. of Structural, Syntactic, and Statistical Pattern Recognition 2004*, 3138, 397-406.
- [15] Marti, R.; Reinelt, G. "The Linear Ordering Problem: Exact and Heuristic Methods in Combinatorial Optimization"; *Springer Science & Business Media*, 2011.
- [16] Gigerenzer, G.; Gaissmaier, W. "Heuristic Decision Making"; *Annu. Rev. Psychol.* 2011, 62, 451-482.
- [17] Baniassadi, Z.; Nezamabadi, H.; Maghfoori Farsangi, M. "A Multiobjective Solution of Gravitational Search Algorithm for Benchmark Functions and Placement of SVC"; *Intelligent Syst. Electrical Eng.* 2011, 1, 59-78 (In Persian).
- [18] Zitzler E. "Evolutionary Algorithms for Multi-Objective Optimization: Methods and Applications"; Ph.D. Thesis, Swiss Federal Institute of Technology, Zurich, 1999.
- [19] Zitzler, E.; Thiele, L. "Multi-objective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach"; *IEEE Trans. Evol. Comput.* 1999, 3, 257-271.
- [20] Kennedy, J.; Eberhart, R. "Particle Swarm Optimization"; *Proc. IEEE Int. Joint Conf. on Neural Networks* 1995, 1942-1948.
- [21] Carlos, A. C. C. "Handling Multiple Objectives with Particle Swarm Optimization"; *IEEE Trans. Evol. Comput.* 2004, 8, 256-279.
- [22] Mozaffari, M. H.; Abdy, H.; Zahiri, S. H. "Application of Inclined Planes System Optimization on Data Clustering"; *IEEE Conf. on Pattern Recognition and Image Analysis* 2013, 1-3.
- [23] Shi, L.; Xi, L.; Ma, X.; Weng, M.; Hu, X. "A Novel Ensemble Algorithm for Biomedical Classification Based on Ant Colony Optimization"; *Appl. Soft Comput.* 2011, 11, 5674-5683.
- [24] Zahiri, S. H.; Seyedin, S. A. "Using Multi-Objective Particle Swarm Optimization for Designing Novel Classifiers"; *Swarm Intelligence for Multi-Objective Problems in Data Mining*, 2009, 242, 65-92.

آن قابلیت اطمینان نسبت به نرخ تشخیص صحیح اهمیت بیشتری داشته باشد و چه بسا در مواردی علی‌رغم نرخ تشخیص صحیح بالا، قابلیت اطمینان کم باشد، بنابراین در این تحقیق، بهبود قابلیت اطمینان به عنوان یک هدف در کنار بهینه‌سازی سائز شورا و نرخ خطا دنبال شده است و نتایج به‌دست آمده، برتری و توانایی الگوریتم بهینه‌سازی سامانه صفحات شیب‌دار را در این زمینه نشان می‌دهد. پس از اثبات برتری عملکرد الگوریتم سامانه صفحات شیب‌دار چند هدفه در افزایش قابلیت اطمینان، به منظور نشان دادن اهمیت وجود معیار قابلیت اطمینان، به بررسی حالتی پرداخته شد که قابلیت اطمینان در توابع هدف در نظر گرفته نشده است و شبیه‌سازی‌ها با دو تابع هدف نرخ خطا و سائز شورا (مطابق تحقیقات مرتبط قبل) انجام شد، سپس قابلیت اطمینان شوراهای ساخته شده محاسبه گردید و درنهایت، مقایسه نتایج به‌دست آمده با حالتی که قابلیت اطمینان به عنوان تابع هدف لحاظ شده است و از این طریق بهینه می‌شود، نشان‌دهنده برتری استفاده از سه تابع هدف به جای دو تابع هدف است چرا که علاوه بر بهبود مقادیر قابلیت اطمینان، مقادیر سائز شورا و نرخ خطا نیز بهبود پیدا کرده‌اند. بررسی پایداری عملکرد طبقه‌بندهای شورایی ابتکاری با قابلیت اطمینان بالا از موضوعات تحقیقاتی آینده در این حوزه است.

۵. مراجع

- [1] Dietterich, T. G. "Ensemble Methods in Machine Learning"; *Proc. of the First Int. Workshop on Multiple Classifier Systems* 2000, 1-15.
- [2] Masoudnia, S.; Ebrahimpour, R. "Mixture of Experts: a Literature Survey"; *Artif. Intell. Rev.* 2014, 42, 275-293.
- [3] Zhou, Z. H.; Wu, J.; Tang, W. "Ensembling Neural Networks: Many Could be Better than AI"; *Artif. Intell.* 2002, 137, 239-263.
- [4] Dos Santos, E. M. "Evolutionary Algorithms Applied to Classifier Ensemble Selection"; *XLIV SBPO/XVI CLAIO* 2012.
- [5] Yang, L. Y.; Zhang, J. Y.; Wang, W. J. "Selecting and Combining Simultaneously with Particle Swarm Optimization"; *Inform. Tech. J.* 2009, 8, 241-245.
- [6] Opitz, D. W. "Feature Selection for Ensembles"; *Proc. of 16th National Conf. on Artificial Intelligence* 1999, 379-384.
- [7] Sirlantzis, K.; Fairhurst, M. C.; Guest, R. M. "An Evolutionary Algorithm for Classifier and Combination Rule Selection in Multiple Classifier Systems"; *Proc. of 16th Int. Conf. on Pattern Recognition* 2002, 2, 771-774.
- [8] Connolly, J. F.; Granger, E.; Sabourin, R. "Dynamic Multi-Objective Evolution of Classifier Ensembles for Video Face Recognition"; *Appl. Soft Comput.* 2013, 13, 3149-3166.

