

دسته‌بندی اهداف سوناری توسط الگوریتم بهینه‌ساز ازدحام ذرات با گروه‌های مستقل

سیدمحمد رضا موسوی^۱، استاد؛ محمد خویشه^۲، دانشجوی دکتری؛ احسان ابراهیمی^۳، دانشجوی دکتری؛ فلاح محمدزاده^۴، کارشناس ارشد

۱- دانشکده مهندسی برق - دانشگاه علم و صنعت ایران - تهران - ایران - m_mosavi@iust.ac.ir

۲- دانشکده مهندسی برق - دانشگاه علم و صنعت ایران - تهران - ایران - m_khishe@elec.iust.ac.ir

۳- دانشکده مهندسی برق - دانشگاه صنعتی شیراز - شیراز - ایران - e.ebrahimi@sutech.ac.ir

۴- دانشکده الکترونیک و مخابرات دریایی - دانشگاه علوم دریایی امام خمینی (ره) - نوشهر - ایران - fallahmohammadzadeh@yahoo.com

چکیده: با توجه به اینکه دادگان سوناری دارای ابعاد بالا و بهینه‌های محلی زیادی می‌باشند، دسته‌بندی‌کننده‌های متعارف توانایی دسته‌بندی مناسب این گونه اهداف را ندارند. استفاده از ترکیب بهینه‌ساز ازدحام ذرات (PSO) و شبکه‌های عصبی مصنوعی (ANN) یکی از راه‌حل‌هایی است که در چند سال اخیر برای غلبه بر این مشکل مورد توجه قرار گرفته است. در کاربرد دادگان با ابعاد بالا، الگوریتم PSO دارای دو مشکل به دام افتادن در کمینه‌های محلی و نرخ همگرایی آهسته می‌باشد. این مقاله به منظور غلبه بر این نقص و رسیدن به نرخ دسته‌بندی مناسب از یک روش فراابتکاری جدید به نام بهینه‌ساز ازدحام ذرات با گروه‌های مستقل (IGPSO) استفاده می‌کند. این الگوریتم با الهام‌گیری از تنوع افراد در تجمع پرندگان یا ازدحام حشرات، دارای توانایی‌های منحصربه‌فردی در دسته‌بندی دادگان ابعاد بالا (سونار) می‌باشد. در ابتدا توانایی‌های IGPSO در کار با دادگان ابعاد بالا توسط ۲۳ تابع آزمون شناخته‌شده به خوبی ارزیابی شده و نتایج به دست آمده با روش PSO و نمونه‌های بهبودیافته PSO مقایسه می‌شوند. نتایج نشان می‌دهد که الگوریتم IGPSO قادر به ارائه نتایجی بسیار بهتر در یافتن کمینه کلی توابع، سرعت همگرایی و اجتناب از کمینه محلی در مقایسه با الگوریتم‌های معیار، مخصوصاً برای توابع با ابعاد بالا است. علاوه بر این، در این مقاله یک کاربرد واقعی از روش ارائه‌شده در زمینه دسته‌بندی دادگان سونار بیان می‌شود. نتایج حاصله نشان می‌دهد که دسته‌بندی‌کننده طراحی‌شده با IGPSO دادگان سونار را با دقت ۹۶/۶۷٪ دسته‌بندی می‌کند، این در حالی است که PSO دقت ۹۲/۳۳٪ را ارائه می‌نماید.

واژه‌های کلیدی: IGPSO، سونار، دسته‌بندی، گروه‌های مستقل ذرات، شبکه‌های عصبی.

Classification of Sonar Targets using Particle Swarm Optimization via Independent Groups

M. R. Mosavi¹, Professor; M. Khishe², PhD Student; E. Ebrahimi³, PhD Student; F. Mohamadzadeh⁴, MSc

1- Department of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran, Email: m_mosavi@iust.ac.ir

2- Department of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran, Email: m_khishe@elec.iust.ac.ir

3- Department of Electrical Engineering, Shiraz University of Technology, Shiraz, Iran, Email: e.ebrahimi@sutech.ac.ir

4- Department of Electrical Engineering, Imam Khomeini University, Noshahr, Iran, Email: fallahmohammadzadeh@yahoo.com

Abstract: Due to the fact that sonar targets have high dimensions and local optimums, conventional classifiers do not have adequate ability to classify these targets. Using a combination of Particle Swarm Optimization (PSO) and Artificial Neural Networks (ANNs) is one of the solutions to overcome this problem. PSO has two drawbacks in high-dimensional datasets: being trapped in local minimums and slow convergence rate. To tackle these deficiencies, this paper uses a newly proposed meta-heuristic algorithm entitled Independent Group Particle Swarm Optimization (IGPSO). This algorithm is inspired by the diversity of individuals in the accumulation of birds or the swarm of insects. It has the unique ability to classify high-dimensional dataset (sonar). In order to test the capabilities of the IGPSO, the algorithm will be evaluated by 23 well-known test functions and the results are compared to PSO and improved versions of PSO. The results show that IGPSO is able to provide much better results in finding the global minimum of functions, convergence speed and local minima avoidance compared with other benchmark algorithms. The results show that the classifier which is designed with IGPSO classifies sonar dataset with accuracy about 96.66 while the accuracy of the PSO-classifier is about 92.33.

Keywords: Sonar, dataset, classification, PSO, IGPSO, neural networks.

تاریخ ارسال مقاله: ۱۳۹۴/۱۱/۱۹

تاریخ اصلاح مقاله: ۱۳۹۵/۰۲/۰۵

تاریخ پذیرش مقاله: ۱۳۹۵/۰۴/۱۹

نام نویسنده مسئول: سیدمحمد رضا موسوی میرکلایی

نشانی نویسنده مسئول: ایران - تهران - نارمک - دانشگاه علم و صنعت ایران - دانشکده مهندسی برق.

۱- مقدمه

اهداف آشکارسازی شده توسط سونار عبارت‌اند از: هدف واقعی، نویز، طنین و کلاتر. نویز دارای انواع مختلفی مانند نویز حرارتی، محیطی، قاره‌ای، لنگرگاه و غیره است که چون از جنس پینگ ارسالی توسط سونار نمی‌باشد، تمایز آن از هدف واقعی آسان است. اکوهای حاصل از برخورد پینگ ارسالی سونار با کف و سطح دریا را طنین گویند [۱]. با توجه به اینکه اکوهای حاصل از طنین دارای یک دامنه یکسان و همگن می‌باشند (علی‌رغم اینکه از جنس پینگ ارسالی هستند)، تمایز آن‌ها از هدف واقعی آسان است. هنگامی که جنس بستر دریا دارای تغییرات زیادی است و در ابعاد کوچک، بستر با جنس‌های مختلفی وجود دارد، اکوهای برگشتی از بستر دارای ویژگی‌های هدف‌گونه بوده، به‌صورتی که حتی تابع چگالی احتمال هدف واقعی و بستر بسیار باهم شبیه خواهند بود. این‌گونه اهداف کاذب را کلاتر گویند [۱]. طبقه‌بندی کلاتر و اهداف واقعی به دلیل تشابه بسیار زیاد اکوهای برگشتی از آن‌ها، کار بسیار دشواری است.

دسته‌بندی‌کننده‌های متعارف آماری (که اکثراً بر مبنای تئوری بیز استوار هستند) به دلیل نیازمندی به محاسبه دانش قبلی و تابع چگالی احتمال (PDF)، وابسته به آزمایش‌ها گسترده بوده و در نتیجه هزینه، زمان و تجهیزات بسیار زیادی را احتیاج دارند. از طرف دیگر با توجه به اینکه مشخصات انتشار صوت در هر نقطه از دریا و در هر بازه زمانی از شب و روز متفاوت است، دسته‌بندی‌کننده‌ای باید انتخاب شود که هم به آزمایش‌ها کم‌تر وابسته باشد و هم قابلیت تطبیق‌پذیری بالایی داشته باشد، از این‌رو شبکه‌های عصبی مصنوعی برای دسته‌بندی هدف واقعی و کلاتر انتخاب می‌شوند. این‌گونه شبکه‌ها می‌توانند با یک مجموع دادگان محدود آموزش ببینند و در سناریوهای آزمایش مختلف به کار برده شوند [۲]. صرف‌نظر از کاربردها، توانایی متمایز شبکه‌های عصبی یادگیری می‌باشد. به‌طور کلی آموزش شبکه‌های عصبی یک چالش برای مسائل بهینه‌سازی غیرخطی است. روش‌های زیادی بر پایه مشتق‌گیری برای تعلیم شبکه‌های عصبی مصنوعی شامل گرادینان نزولی (GD) و پس انتشار (BP) [۳] استفاده شده‌اند. علاوه بر روش‌های مبتنی بر مشتق، روش‌های بدون مشتق‌گیری، از جمله الگوریتم ژنتیک (GA)، ازدحام ذرات (PSO) و جستجوی گرانشی (GSA) در آموزش شبکه‌های عصبی استفاده شده است [۴].

هدف نهایی فرآیند یادگیری در شبکه‌های عصبی، پیدا کردن بهترین ترکیب از پارامترهای شبکه می‌باشد به‌طوری‌که در آموزش شبکه و نمونه‌های آزمایش، کم‌ترین مقدار خطا را داشته باشیم. روش‌های ابتکاری و فراابتکاری به مشتق‌گیری از توابع هدف نیاز ندارد. از سوی دیگر با توجه به پیدا کردن کمینه کلی خیلی بهتر از روش‌های مبتنی بر مشتق‌گیری (که در کمینه‌های محلی گیر می‌کنند)، عمل می‌نمایند. همچنین آن‌ها می‌توانند کاربرد خود را در محدوده وسیعی از توابع هدف و ساختار شبکه‌های عصبی گسترش دهند.

بهینه‌سازی ازدحام ذرات^۱ (PSO) یکی از الگوریتم‌های تکاملی^۲ است که از رفتار اجتماعی حیوانات الهام گرفته شده است [۵]. سادگی و هزینه محاسباتی کم، این الگوریتم را بسیار محبوب کرده است. با وجود این مزایا، به دام افتادن در کمینه محلی^۳ و نرخ همگرایی آهسته^۴ دو مشکل غیرقابل‌اجتناب می‌باشند [۶] که در همه انواع الگوریتم‌های تکاملی رایج هستند. این مشکلات با افزایش ابعاد مسئله بدتر می‌شوند.

در این مقاله سعی بر این است که با استفاده از الگوریتم IGPSO به دسته‌بندی دادگان سوناری که دارای ابعاد بالای هستند، بپردازیم. بدین منظور در بخش اول، الگوریتم PSO توضیح داده خواهد شد. در بخش دوم، نحوه استخراج IGPSO از PSO بیان می‌شود. در قسمت سوم، کارایی IGPSO در کار با دادگان ابعاد بالا اثبات می‌گردد. در قسمت چهارم، دادگان سونار توسط دسته‌بندی‌کننده طراحی‌شده با شبکه‌های عصبی و IGPSO دسته‌بندی شده و درنهایت در بخش آخر نتیجه‌گیری و پیشنهاد کارهای آینده ارائه خواهد شد.

۲- الگوریتم PSO

الگوریتم PSO از رفتار اجتماعی پرندگان الهام گرفته شده است. این روش از تعدادی از ذرات (راه‌حل‌های نامزد) که در فضای جستجو به دنبال یافتن بهترین راه‌حل هستند، استفاده می‌کند. در همین حال همه ذرات به‌سوی بهترین ذره‌ای (بهترین راه‌حل) که در مسیرشان وجود دارد، حرکت می‌کنند. به عبارت دیگر، ذرات بهترین راه‌حل‌های خود را به‌عنوان بهترین راه‌حل کلی در نظر می‌گیرند. هر ذره در بهینه‌ساز ازدحام ذرات باید پارامترهایی مانند موقعیت فعلی، سرعت فعلی، فاصله تا $pbest$ و فاصله تا $gbest$ را به‌منظور تغییر موقعیت خود در نظر بگیرد. مدل‌سازی ریاضی بهینه‌ساز ازدحام ذرات به‌صورت روابط (۱) و (۲) است.

$$v_i^{t+1} = wv_i^t + c_1 \times rand \times (pbest_i - \chi_i^t) + c_2 \times rand \times (gbest - \chi_i^t) \quad (1)$$

$$\chi_i^{t+1} = \chi_i^t + v_i^{t+1} \quad (2)$$

در روابط بالا، v_i^t مبین سرعت^۵ ذره نام در تکرار t ام، w مبین تابع وزن^۶، c_1 مبین ضریب شتاب^۷ و $rand$ نشان‌دهنده یک عدد تصادفی بین ۰ و ۱ است. χ_i^t مبین موقعیت فعلی ذره نام در تکرار t ام می‌باشد. همچنین $pbest_i$ ، بهترین راه‌حل عامل نام در تکرار t ام است و بهترین راه‌حلی که تاکنون پیدا شده، $gbest$ می‌باشد.


۳- الگوریتم IGPSO

مفهوم گروه‌های مستقل از تنوع افراد در تجمع حیوانات و یا ازدحام حشرات الهام گرفته شده است. در هر جمعی، افراد از لحاظ هوش و توانایی کاملاً مشابه نیستند، اما همه آن‌ها وظایف خود را به‌عنوان عضوی از گروه انجام می‌دهند [۷]. توانایی هر فرد می‌تواند در یک


$pbest$ و تناسب ذرات تعریف می‌شوند. هر ذره با به‌کارگیری راهبرد گروهی خود، ضرایب C_1 و C_2 را به‌روزرسانی می‌کند. پس از محاسبه C_1 و C_2 ، سرعت و موقعیت ذرات با استفاده از رابطه‌های (۱) و (۲) به‌روزرسانی می‌شوند.

جدول ۱: به‌روزرسانی راهبردها

روابط به‌روزرسانی		الگوریتم
C_1	C_2	
IGPSO1		
$(-2.05/T)t + 2.55$	$(1/T)t + 1.25$	گروه ۱
$(-2.05/T)t + 2.55$	$(2t^3/T) + 0.5$	گروه ۲
$(-2t^3/T^3) + 2.5$	$(1/T)t + 1.25$	گروه ۳
$(-2t^3/T^3) + 2.5$	$(2t^3/T) + 0.5$	گروه ۴
IGPSO2		
$2.5 - (2\log(t)/\log(T))$	$(2\log(t)/\log(T)) + 0.5$	گروه ۱
$(-2t^3/T^3) + 2.5$	$(2t^3/T) + 0.5$	گروه ۲
$0.5 + 2\exp[-(4t/T)^2]$	$2.2 - 2\exp[4t/T^2]$	گروه ۳
$2.5 + 2(t/T)^2 - 2(2t/T)$	$0.5 - 2(t/T)^2 + 2(2t/T)$	گروه ۴
IGPSO3		
$1.95 - 2t^{1/3}/T^{1/3}$	$2t^{1/3}/T^{1/3} + 0.05$	گروه ۱
$(-2t^3/T^3) + 2.5$	$(2t^3/T) + 0.5$	گروه ۲
$1.95 - 2t^{1/3}/T^{1/3}$	$(2t^3/T) + 0.5$	گروه ۳
$(-2t^3/T^3) + 2.5$	$2t^{1/3}/T^{1/3} + 0.05$	گروه ۴



شکل ۱: مدل‌های ریاضی از گروه‌های مستقل برای IGPSO1



شکل ۲: مدل‌های ریاضی از گروه‌های مستقل برای IGPSO2

وضعیت خاص مفید باشد. به‌عنوان مثال، در یک کلونی موربانه، چهار نوع موربانه به نام‌های سرباز، کارگر، پرستار بچه و ملکه وجود دارند. آن‌ها از توانایی‌های متنوعی برخوردارند، اما این تفاوت‌ها برای بقای کلونیشان لازم است. این چهار نوع موربانه را می‌توان به‌عنوان چهار گروه مستقل در نظر گرفت که یک هدف مشترک گروهی دارند و آن بقای کلونی است [۸].

در PSO متداول تمام ذرات به‌طور مشابه در جستجوی محلی و عمومی رفتار می‌کنند. در این حالت، ذرات را می‌توان به‌عنوان یک گروه با یک راهبرد جستجو در نظر گرفت. باین‌حال به‌لحاظ نظری در هر الگوریتم بهینه‌سازی مبتنی بر جمعیت، می‌توان با استفاده از گروه‌های مستقل متفاوت که هدفی مشترک دارند، نتیجه جستجوی تصادفی و مستقیم را به‌طور همزمان به دست آورد. در این مقاله، برای به‌روزرسانی C_1 و C_2 از گروه‌های مستقل توسط روابط ارائه‌شده در [۹] استفاده شده است.

در این بخش چهار گروه مستقل که از کلونی موربانه‌ها الهام گرفته شده‌اند، تعریف می‌شوند. این چهار گروه مستقل از الگوهای خود برای جستجو در فضای مسئله به‌صورت محلی و عمومی استفاده می‌کنند. همچنین سه نسخه مختلف از PSO با گروه‌های مستقل متفاوت بنام IGPSO1، IGPSO2، IGPSO3 ایجاد می‌شوند. ضرایب پویای این الگوریتم‌ها در جدول ۱ و شکل‌های ۱ تا ۳ معرفی شده‌اند. در این جدول، T نمایانگر حداکثر تعداد تکرارها است و t تکرار فعلی را نشان می‌دهد.

به‌منظور بررسی اثرات توابع مختلف بر عملکرد PSO، طیف وسیعی از توابع استفاده شده است. این توابع با دامنه، انحنا و نقاط تلاقی مختلف انتخاب شده‌اند. به‌عنوان مثال، ذرات IGPSO1 در گروه ۱ قبل از گروه‌های دیگر تمایل به رفتار اجتماعی دارند. این موضوع توسط گروه ۲ دنبال می‌شود. در مقابل، ذرات گروه ۴ ترجیح می‌دهند که در اکثر تکرارها به جستجوی شخصی بپردازند، به‌طوری‌که نقاط تقاطع C_1 و C_2 در نزدیک آخرین تکرارها است. ممکن است مشاهده شود که IGPSO1 از دو تابع خطی برای گروه ۱، توابع خطی و مکعب برای گروه‌های ۲ و ۳ و دو تابع مکعب در گروه ۴ استفاده می‌کند. IGPSO2 به‌ترتیب دو تابع لگاریتمی، دو تابع مکعب، دو تابع نمایی و دو تابع درجه دوم را برای گروه‌های ۱ تا ۴ به‌کار می‌برد.

لازم به‌ذکر است که این توابع از الگوهای مختلف برخوردار هستند و در طول دوره‌های تکرار متغیرند. به‌عنوان مثال ذرات گروه ۱ بسیار زودتر از ذرات گروه ۲ در IGPSO2 تمایل به تغییر توانایی جستجو عمومی و محلی دارند. الگوریتم IGPSO3 از دو تابع ریشه سوم، دو تابع مکعب برای گروه‌های ۱ و ۲ و همچنین یک تابع ریشه سوم و تابع مکعب برای گروه‌های ۳ و ۴ استفاده می‌کند.

در IGPSO ابتدا همه ذرات به‌صورت تصادفی در فضای جستجوی مسئله قرار می‌گیرند. پس‌از آن، ذرات به‌طور تصادفی به برخی گروه‌های مستقل از پیش تعریف‌شده تقسیم می‌گردند. در هر تکرار، $gbest$


در مقابله با مسائل با ابعاد بالا، توابع چندوجهی با ۳۰۰ بعد انتخاب شده‌اند. همچنین ۱۰ تابع معیار با بعد ثابت نیز برای ارائه یک مطالعه جامع انتخاب شده‌اند.

به‌منظور تأیید اعتبار نتایج IGPSO، این الگوریتم با PSO کلاسیک و برخی الگوریتم‌های PSO اصلاح‌شده مانند: SPSO [۵]، TACPSO [۱۳]، MPSO [۱۴] و IPSO [۱۵] مقایسه می‌شوند.

۳-۴- تجزیه و تحلیل عملکرد

برای مقایسه عملکرد تمامی الگوریتم‌ها، میانگین نتایج بیش از ۱۰ اجرا جمع‌آوری شده است. میانگین بهترین راه‌حل‌ها در آخرین تکرار، در جداول ۶ تا ۸ نمایش داده شده است. بهترین نتایج با رنگ سیاه مشخص شده است.

جدول ۶ نتایج توابع تک‌وجهی را نشان می‌دهد. همان‌طور که از این جدول قابل‌مشاهده است، IGPSO2 و IGPSO3 بهترین نتایج را در ۵ عدد از ۷ تابع معیار تک‌وجهی دارا می‌باشند. یعنی مقدار به‌دست‌آمده توسط الگوریتم که در جدول ۶ نمایش داده شده است، به مقدار واقعی کمینه کلی که در جدول ۳ نمایش داده شده است، نزدیک‌تر است. این نتایج نشان می‌دهد که گروه‌های مستقل می‌توانند عملکرد الگوریتم PSO را برای این توابع معیار بهبود ببخشند. شکل ۴ منحنی‌های همگرایی الگوریتم‌ها را نشان می‌دهد. همان‌طور که می‌توان از این منحنی مشاهده نمود، IGPSO2 و IGPSO3 از بهترین نرخ‌های همگرایی برای بسیاری از توابع معیار برخوردار هستند. شایان ذکر است که توابع معیار تک‌وجهی فقط یک کمینه عمومی دارند و هیچ کمینه محلی در فضای جستجوی آن‌ها وجود ندارد. بنابراین این نوع از توابع برای تعیین معیار توانایی همگرایی الگوریتم‌ها مناسب می‌باشند. در نتیجه، نتایج حاصل از الگوریتم‌های IGPSO نشان می‌دهد که گروه‌های مستقل می‌توانند توانایی همگرایی الگوریتم PSO را به‌طور معناداری بهبود ببخشند. دلیل برتری نتایج این است که ذرات از تنوع جمعیتی برخوردارند و به‌طور مؤثر قادر به بهره‌برداری از دانش محلی، در نزدیکی راه‌حل‌های بهینه می‌باشند.



شکل ۳: مدل‌های ریاضی از گروه‌های مستقل برای IGPSO3

۴- بحث و نتایج تجربی

در این بخش ابتدا توانایی الگوریتم IGPSO در یافتن کمینه محلی و سرعت همگرایی مورد آزمایش قرار می‌گیرد. پس از اثبات توانایی IGPSO در کار با دادگان ابعاد بالا، الگوریتم ذکرشده برای کاربرد عملی دسته‌بندی دادگان سونار استفاده می‌شود.

۴-۱- تنظیم پارامتر

ضرایب SPSO، TACPSO، MPSO و IPSO در جدول ۲ آمده‌اند. وزن اینرسی w برای همه الگوریتم‌های IGPSO1 تا IGPSO3 به‌طور خطی از ۰/۹ تا ۰/۴ کاهش می‌یابد. تعداد ذرات موجود ۱۰۰ عدد و حداکثر تعداد تکرارها ۵۰۰ می‌باشد.

۴-۲- آزمودن توابع معیار

همان‌طور که در جداول ۳ تا ۵ نشان داده شده است، ۲۳ تابع استاندارد معیار (که در اکثر مقالات مربوط به الگوریتم‌های بهینه‌ساز به‌عنوان معیار سنجش بکار برده می‌شوند)، برای بررسی عملکرد IGPSO اعمال می‌شوند و هدف از آن‌ها یافتن کمینه عمومی است [۹-۱۲]. این توابع معیار را می‌توان به سه گروه تک‌وجهی، چندوجهی و چندوجهی با بعد ثابت تقسیم نمود. در این جدول‌ها، dim بعد توابع d ، V_h محدوده فضای جستجو و f_{min} مقدار کمینه تابع است. لازم به ذکر است که برای بررسی عملکرد روش پیشنهادی

جدول ۲: به‌روزرسانی راهبردها

روابط به‌روزرسانی		الگوریتم
C_1	C_2	
2	2	SPSO
$2.2 - 2\exp[-(4t/T)^2]$	$2.2 - 2\exp[-(4t/T)^2]$	TACPSO
$(-2.05/T)t + 2.55$	$(1/T)t + 1.25$	MPSO
$2.5 + 2(t/T)^2 - 2(2t/T)$	$0.5 - 2(t/T)^2 + 2(2t/T)$	IPSO

جدول ۳: توابع معیار تک‌وضعی

تابع	بعد	بازه	$f_{\min}$
$f_1(x) = \sum_{i=1}^n x_i^2$	۳۰۰	$[-100, 100]$	۰
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	۳۰۰	$[-10, 10]$	۰
$f_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	۳۰۰	$[-100, 100]$	۰
$f_4(x) = \max_i \{ x_i , 1 \leq i \leq n\}$	۳۰۰	$[-100, 100]$	۰
$f_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i)^2 + (x_i - 1)^2]$	۳۰۰	$[-30, 30]$	۰
$f_6(x) = \sum_{i=1}^n [(x_i + 0.5)^2]$	۳۰۰	$[-100, 100]$	۰
$f_7(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0,1)$	۳۰۰	$[-1/28, 1/28]$	۰

جدول ۴: توابع معیار چندوضعی

تابع	بعد	بازه	$f_{\min}$
$F_8(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	۳۰۰	$[-500, 500]$	-۴۱۸/۹۸
$F_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	۳۰۰	$[-5/12, 5/12]$	۰
$F_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	۳۰۰	$[-32, 32]$	۰
$F_{11}(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	۳۰۰	$[-600, 600]$	۰
$F_{12}(x) = \frac{\pi}{n} \{10 \sin(\pi y_i) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2\} + \sum_{i=1}^n u(x_i, 10, 100, 4)$ $y_i = 1 + \frac{x_i + 1}{4}$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	۳۰۰	$[-50, 50]$	۰
$F_{13}(x) = 0.1 \{\sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)]\} + \sum_{i=1}^n u(x_i, 5, 100, 4)$	۳۰۰	$[-50, 50]$	۰







افزایش داده‌اند. همان‌طور که در شکل ۴ مشاهده می‌شود، نرخ همگرایی الگوریتم IGPSO بهتر از الگوریتم‌های دیگر می‌باشد. دلیل بهبود توانایی IGPSO در اجتناب از کمینه محلی گروه‌های مستقل است. این عمل با جستجو تصادفی بیش‌تر در مقایسه با الگوریتم‌های اصلاح‌شده PSO حاصل شده است. در این حالت ذرات نمی‌توانند به‌آسانی در کمینه محلی به دام افتند.


توابع معیار چندوضعی با بعد ثابت در مقایسه با توابع چندوضعی، کمینه محلی کم‌تری دارند. همان‌طور که در جدول ۸ نشان داده شده است، نتایج حاصل از تمام الگوریتم‌ها در ۶ عدد از توابع برابر هستند. شکل ۴ رفتار همگرایی الگوریتم‌ها را در مقابله با توابع با بعد ثابت نشان می‌دهد. تمام الگوریتم‌ها از منحنی‌های همگرایی نزدیک برخوردارند.


نتایج برای توابع معیار چندوضعی در جدول ۷ ارائه می‌شوند. در مقایسه با توابع تک‌وضعی، این توابع معیار از کمینه‌های محلی بسیار بیش‌تری برخوردار هستند که با افزایش ابعاد مسئله به‌طور نمایی افزایش می‌یابند. بنابراین آن‌ها برای تعیین میزان قابلیت الگوریتم‌ها در اجتناب از کمینه محلی مناسب می‌باشند. همان‌طور که نتایج نشان می‌دهد، در بسیاری از توابع معیار چندوضعی، IGPSO2 و IGPSO3 از نظر سرعت همگرایی و یافتن بهینه کلی بهتر از الگوریتم‌های دیگر عمل می‌کنند. تابع F12 تنها تابع معیاری است که در آن نتایج IGPSO از SPSO بهتر نیست. با این حال نتایج حاصل از این دو الگوریتم خیلی نزدیک هستند. به‌طور کلی، الگوریتم‌های IGPSO از بهترین نتایج برخوردارند. نتایج جدول ۷ نشان می‌دهد که گروه‌های مستقل عملکرد الگوریتم PSO را از نظر اجتناب از کمینه‌های محلی

جدول ۵: توابع معیار چندوجهی با بعد ثابت

تابع	بعد	بازه	$f_{\min}$
$F_{14}(x) = \left(\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)^{-1}$	۲	$[-۶۵, ۶۵]$	۱
$F_{15}(x) = \sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	۴	$[-۵, ۵]$	۰/۰۰۰۳
$F_{16}(x) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$	۲	$[-۵, ۵]$	-۱/۰۳۱۶
$F_{17}(x) = \left(x_2 - \frac{5.1}{4\pi^2}x_1^2 + \frac{5}{\pi}x_1 - 6 \right)^2 + 10 \left(1 - \frac{1}{8\pi} \right) \cos x_1 + 10$	۲	$[-۵, ۵]$	۰/۳۹۸
$F_{18}(x) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 - 3x_2)^2 \times (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	۲	$[-۲, ۲]$	۳
$F_{19}(x) = -\sum_{i=1}^4 c_{ij} \exp(-\sum_{j=1}^3 a_{ij}(x_j - p_{ij})^2)$	۳	$[۱, ۳]$	-۳/۸۶
$F_{20}(x) = -\sum_{i=1}^4 c_{ij} \exp(-\sum_{j=1}^6 a_{ij}(x_j - p_{ij})^2)$	۶	$[۰, ۱]$	-۳/۳۲
$F_{21}(x) = -\sum_{i=1}^5 [(X - a_i)(X - a_i)^T + c_i]^{-1}$	۴	$[۰, ۱۰]$	-۱۰/۱۵۳۲
$F_{22}(x) = -\sum_{i=1}^7 [(X - a_i)(X - a_i)^T + c_i]^{-1}$	۴	$[۰, ۱۰]$	-۱۰/۴۰۲۸
$F_{23}(x) = -\sum_{i=1}^{10} [(X - a_i)(X - a_i)^T + c_i]^{-1}$	۴	$[۰, ۱۰]$	-۱۰/۵۳۶۳


 F₄

 F₁

 F₅

 F₂

 F₆

 F₃





شکل ۴: منحنی‌های همگرایی الگوریتم‌ها بر روی توابع معیار

جدول ۶: مقایسه نتایج تمام الگوریتم‌ها در توابع معیار تک‌وضعی

IGPSO1	IGPSO2	IGPSO3	SPSO	MPSO	TACPSO	IPSO	تابع آزمون
۰/۰۵۷۵۸۷	۰/۰۳۲۲۳۷	۰/۰۱۰۵۴	۴/۵۵۱۵	۰/۱۵۱۴۲	۰/۱۰۳۲۷	۰/۰۵۷۵۸۷	F1
۰/۳۵۶۵۲	۱/۵۵۵۴	۰/۱۲۴۹۹	۳/۴۷۶۶	۲۰/۰۹۵۵	۱/۰۳۲۵	۰/۳۵۶۵۲	F2
۱۳۳۹/۱۹۹۲	۱۳۹۳/۲۰۵۱	۹۳/۵۵۶۳	۲۲/۲۴۵۶	۶۳۳۱/۰۶۲۵	۱۲۵۱/۲۱۲۷	۱۱۳۹/۱۹۹۲	F3
۱۵/۲۳۲۶	۲۱/۳۱۲۱	۱۷/۱۹۸۶	۲/۲۰۳۶	۵/۱۲۳۴	۵/۶۲۴۸	۱۵/۲۳۲۶	F4
۱۸۶/۶۱۱۵	۵۰/۵۹۶۱	۱۵۲/۳۹۶۹	۸۶/۰۸۱۷	۵۷۸/۱۵۲۴	۴۱۳/۳۸۵۹	۱۸۶/۶۱۱۵	F5
۰/۲۷۷۲۶	۰/۰۹۸۱۷۴	۰/۰۹۳۰۲۹	۱/۴۳۷	۰/۲۶۶۵۹	۰/۱۴۴۶۳	۰/۲۷۷۲۶	F6
۰/۰۷۴۱۱۶	۰/۰۲۷۸۵	۰/۰۶۱۸۳۲	۵/۷۸۹۸	۰/۱۱۹	۰/۰۷۱۳۳۴	۰/۰۷۴۱۱۶	F7


جدول ۷: مقایسه نتایج تمام الگوریتم‌ها در توابع چندوضعی

IGPSO1	IGPSO2	IGPSO3	SPSO	MPSO	TACPSO	IPSO	تابع آزمون
-۷۸۰۶/۱۶۳۲	-۹۱۲۲/۶۰۱۶	-۱۰۴۲۲/۴۸۸۵	-۷۵۵۲/۵۹۶۶	-۸۴۰۲/۸۷۳۲	-۸۳۳۰/۱۵۵۳	-۷۸۰۶/۱۶۳۲	F8
۶۷/۷۲۶۳	۴۸/۸۹۳۴	۵۴/۷۲۴۵	۱۳۱/۹۱۱۴	۱۳۵/۳۶۶۱	۸۲/۶۵۳۵	۶۷/۷۲۶۳	F9
۳/۸۸۷۱	۲/۱۲۱	۲/۵۰۶۶	۳/۰۴۸	۳/۳۳۵۵	۳/۱۸۷۴	۳/۸۸۷۱	F10
۰/۳۴۵۲۸	۰/۰۲۶۰۰۸	۰/۰۵۳۹۳۳	۰/۱۰۰۳۳	۰/۱۶۷۵۷	۰/۰۶۶۶۱۷	۰/۳۴۵۲۸	F11
۴/۰۴۲۶	۲/۴۰۳۶	۲/۷۵۲۲	۰/۱۰۰۵۸	۰/۲۹۷۴۸	۴/۶۵۱۸	۴/۰۴۲۶	F12
۲۴/۷۲۸۳	۲۷/۱۷۲۹	۰/۴۳۱۶۳	۰/۵۵۵۵۲	۵/۵۳۸۸	۱۱/۹۳۸۴	۲۴/۷۲۸۳	F13

جدول ۸: مقایسه نتایج در میان تمامی الگوریتم‌ها در توابع معیار چندوضعی با بعد ثابت

IGPSO1	IGPSO2	IGPSO3	SPSO	MPSO	TACPSO	IPSO	تابع آزمون
۰/۹۹۸	۰/۹۹۸	۰/۹۹۸	۵/۹۲۸۸	۰/۹۹۸	۰/۹۹۸	۰/۹۹۸	F14
۰/۰۰۱۰۲۲۳۲	۰/۰۰۳۱۱۸۴	۰/۰۰۰۵۷۹۰۱	۰/۰۰۱۰۷	۰/۰۰۰۷۸۲۶۶	۰/۰۰۰۷۸۲۶۶	۰/۰۰۱۰۲۲۳۲	F15
-۱/۰۳۱۶	-۱/۰۳۱۶	-۱/۰۳۱۶	-۱/۰۳۱۶	-۱/۰۳۱۶	-۱/۰۳۱۶	-۱/۰۳۱۶	F16
۰/۳۹۷۸۹	۰/۳۹۷۸۹	۰/۳۹۷۸۹	۰/۳۹۷۸۹	۰/۳۹۷۸۹	۰/۳۹۷۸۹	۰/۳۹۷۸۹	F17
۳	۳	۳	۳	۳	۳	۳	F18
-۳/۸۶۲۸	-۳/۸۶۲۸	-۳/۸۶۲۸	-۳/۸۶۲۸	-۳/۸۶۲۸	-۳/۸۶۲۸	-۳/۸۶۲۸	F19
-۳/۲۵۸۶	-۳/۲۵۸۶	-۳/۲۵۸۶	-۳/۲۵۸۶	-۳/۲۵۸۶	-۳/۲۵۸۶	-۳/۲۵۸۶	F20
-۵/۱۰۰۸	-۲/۶۸۲۹	-۱/۱۵۳۲	-۱/۱۵۳۲	-۲/۶۸۲۹	-۲/۶۸۲۹	-۵/۱۰۰۸	F21
-۵/۱۲۸۸	-۱/۰۴۰۲۹	-۱/۰۴۰۲۹	-۱/۰۴۰۲۹	-۱/۰۴۰۲۹	-۱/۰۴۰۲۹	-۵/۱۲۸۸	F22
-۱/۵۳۶۴	-۱/۵۳۶۴	-۱/۵۳۶۴	-۱/۵۳۶۴	-۲/۸۷۱۱	-۳/۸۳۵۴	-۱/۵۳۶۴	F23

دست می‌آید. در این آزمایش پوش طیفی از ۶۰ نمونه طیفی که بین ۱ و نرمالیزه شده‌اند، تشکیل شده است. هرکدام از این اعداد نماینده مجموع انرژی موجود در دریچه نمونه‌برداری مربوطه است؛ به‌عنوان مثال انرژی موجود در دریچه اول ($\eta = 0$) بعد از نرمالیزه‌شدن، عدد اول از ۶۰ عدد موجود در بردار ویژگی را تشکیل می‌دهد.



شکل ۶: نمونه‌ای از اکوی دریافتی صخره (کلاتر) و هدف واقعی (سیلندر فلزی)

۴-۴-۲- دسته‌بندی اهداف سوناری

پس از پیش‌پردازش انجام‌شده بر روی اکوهای بازگشتی سونار و به دست آوردن مجموعه داده نرمالیزه شده بین صفر و یک، در این قسمت از مقاله مجموعه داده با ابعاد 60×208 (۲۰۸ نمونه که هرکدام دارای ۶۰ ویژگی هستند) به شبکه عصبی RBF که توسط الگوریتم‌های IGPSO، MPSO، TACPSO، PSO، IPSO و IGPSO آموزش داده شده است، اعمال می‌شود. بخش بعدی نحوه آموزش شبکه عصبی RBF را به‌منظور دسته‌بندی دادگان سونار توضیح می‌دهد.

۴-۴-۳- آموزش شبکه‌های عصبی RBF با استفاده از الگوریتم IGPSO

به‌طورکلی، سه روش استفاده از الگوریتم‌های تکاملی برای آموزش شبکه‌های عصبی RBF وجود دارد. اولین روش عبارت است از به‌کارگیری شبکه‌های تکاملی به‌منظور یافتن ترکیب وزن یال‌ها، بایاس گرهای خروجی، پارامترهای انتشار تابع اساسی و بردارهای مراکز لایه پنهان برای داشتن کم‌ترین مقدار خطا در یک شبکه عصبی RBF. دومین شیوه عبارت است از به‌کارگیری شبکه‌های تکاملی به‌منظور


۴-۴-۲- دسته‌بندی دادگان سونار

در این قسمت به‌منظور سنجش الگوریتم IGPSO در زمینه دادگان واقعی، دادگان هدف واقعی و کلاتر سونار فعال با استفاده از یک دسته‌بندی‌کننده RBF که توسط الگوریتم IGPSO آموزش دیده است، دسته‌بندی می‌شود. سپس نتایج با دسته‌بندی‌کننده‌ای که با الگوریتم‌های IGPSO، MPSO، TACPSO، PSO، IPSO آموزش دیده است، مقایسه می‌شود.

۴-۴-۱- دادگان سونار

دادگان سونار مورد استفاده در این مقاله از آزمایش Gorman و Sejnowski موجود در مراجع [۱۶، ۱۷] استخراج شده است. در این آزمایش دو نوع اکو^۸ (سیگنال بازگشتی) وجود دارد، اولی مربوط به یک سیلندر فلزی (نقش هدف واقعی را بر عهده دارد) و دومی مربوط به یک صخره هم‌اندازه سیلندر (نقش کلاتر یا هدف کاذب را ایفا می‌کند) هستند. همان‌گونه که در شکل ۵ مشاهده می‌شود، ویژگی هدف واقعی و کلاتر بسیار شبیه هم است و با یک دسته‌بندی‌کننده خطی یا غیرخطی مرتبه‌پایین نمی‌توان آن‌ها را از یکدیگر تفکیک کرد (برای قابل مشاهده‌بودن، دادگان به ۳ بعد کاهش داده شده‌اند) [۱۸].

در این آزمایش یک سیلندر فلزی به طول ۵ فوت و یک صخره هم‌اندازه با آن در بستر شنی دریا قرار داده شده‌اند و یک پالس چیرپ FM خطی پهن باند^۹ ($ka=55/6$) به سمت آن‌ها فرستاده شده است. اکوهای برگشتی در فاصله ۱۰ متری از آن‌ها جمع‌آوری شده است. بر اساس SNR اکوی دریافتی، از ۱۲۰۰ اکو جمع‌آوری شده ۲۰۸ اکو که SNR آن‌ها بین ۴dB تا ۱۵dB است، انتخاب شده‌اند. از این ۲۰۸ اکو، ۱۱۱ عدد مربوط به سیلندر فلزی و ۹۷ عدد مربوط به صخره هستند. شکل ۶ نمونه‌هایی از اکوهای دریافتی از صخره و سیلندر فلزی را نشان می‌دهد.



شکل ۵: ترسیم پراکندگی دادگان سونار

پیش‌پردازش استفاده‌شده برای به‌دست آوردن پوش طیفی در شکل ۷ نشان داده شده است. در شکل ۷-الف مجموعه‌ای از دریچه‌های نمونه‌برداری مشاهده می‌شود؛ در شکل ۷-ب مجموعه دریچه‌های نمونه‌برداری بر روی طیف‌نگاره دوبعدی تابع فوریه اکوی سونار قرار گرفته‌اند. پوش طیفی توسط جمع‌آوری اثرات هر دریچه به

برای نمایش باینری، هر عنصر به صورت رشته‌ای از بیت‌های باینری نمایش داده می‌شود. هرکدام از این شیوه‌های نمایش، مزایا و معایب خاص خود را دارد که می‌تواند در یک مسئله خاص مفید واقع گردد.

در روش نخست، تبدیل عناصر به بردار، ماتریس و یا رشته‌ای از بیت‌های باینری آسان می‌باشد، اما فرآیند بازیابی آن‌ها پیچیده خواهد بود. به همین دلیل اغلب این روش در شبکه‌های عصبی ساده مورد استفاده قرار می‌گیرد. در روش دوم برای شبکه‌های با ساختار پیچیده، بازیابی آسان‌تر از کد کردن عناصر است. این روش برای الگوریتم‌های یادگیری در شبکه‌های عصبی عمومی بسیار مناسب است. در روش سوم، نیاز است که متغیرها به صورت باینری نمایش داده شوند. در این حالت وقتی که ساختار شبکه پیچیده گردد، طول هر عنصر نیز افزایش می‌یابد. بنابراین فرآیند کد کردن و دیکد کردن خیلی پیچیده خواهد شد.

در این مقاله، چون با شبکه‌های عصبی RBF پیچیده سروکار نداریم، از روش برداری استفاده شده است. به منظور کاهش زمان اجرای برنامه شبکه‌های عصبی RBF، از جعبه‌ابزارهای عمومی Matlab استفاده نخواهد شد. همان‌طور که قبلاً اشاره شد، آموزش شبکه عصبی RBF را می‌توان با انتخاب مقادیر بهینه برای پارامترهای زیر به دست آورد:

- وزن‌های بین لایه‌های پنهان و لایه خروجی (W)
- پارامترهای انتشار تابع اساسی لایه پنهان (α)
- بردارهای مرکز لایه پنهان (C)
- پارامترهای بایاس نرون‌های لایه خروجی (β)


تعداد نرون‌های لایه پنهان در شبکه‌های عصبی بسیار مهم است. به کارگیری نرون‌ها بیش‌تر از آنچه مورد نیاز است منجر به بیش‌آموزش^{۱۰} شبکه، افزایش پیچیدگی ساختاری و زمان اجرای الگوریتم می‌شود. با توجه به مرجع [۲۰] و بررسی‌های به عمل آمده در آن تعداد نرون‌های لایه مخفی ۹ عدد انتخاب می‌شود. با افزایش بیش‌تر تعداد نرون‌های لایه مخفی، درحالی‌که پیچیدگی مکانی و زمانی شبکه را افزایش می‌دهیم، اما عملکرد شبکه به مقدار قابل‌توجهی افزوده نمی‌شود. ذره‌های الگوریتم IGPSO شامل پارامترهای وزن ($\vec{W}$)، انتشار ($\vec{\alpha}$)، بردارهای مرکز ($\vec{C}$) و بردارهای بایاس ($\vec{\beta}$) است. یک ذره در الگوریتم IGPSO می‌تواند به صورت رابطه (۳) بیان شود.

$$P_i = [\vec{w} \vec{\alpha} \vec{c} \vec{\beta}] \quad (3)$$


همان‌طور که ذکر شد هدف نهایی روش‌های یادگیری، آموزش شبکه‌های عصبی مصنوعی است. مهم‌ترین بخش در یادگیری، فرآیند آموزش است. هر نمونه آموزش باید شامل محاسبه شاخص مناسب بودن همه ذره‌ها باشد. در این مقاله تابع شاخص مناسب بودن^{۱۱} ذره (برای همه نمونه‌های آموزش) به روش مجموع مربعات خطا^{۱۲} و به صورت رابطه (۴) محاسبه می‌گردد.

$$f = E^{SSE} \quad (4)$$

یافتن ساختار مناسب شبکه عصبی RBF در یک مسئله خاص و آخرین شیوه شامل به کارگیری شبکه‌های تکاملی به منظور یافتن پارامترهای الگوریتم یادگیری مبتنی بر گرادینان از قبیل نرخ یادگیری و اندازه حرکت است. در این مقاله، الگوریتم IGPSO با استفاده از شیوه نخست به یک شبکه عصبی RBF اعمال می‌گردد. به منظور طراحی یک الگوریتم آموزش‌دهنده برای شبکه‌های عصبی RBF، لازم است در الگوریتم IGPSO، وزن یال‌ها، بایاس گره‌های خروجی، پارامترهای انتشار تابع اساسی لایه پنهان و بردارهای مراکز لایه پنهان به صورت مناسب نمایش داده شوند.



(الف)



(ب)

شکل ۷: (الف) مجموعه‌ای از دریچه‌های نمونه‌برداری و (ب)

پیش پردازش استفاده شده برای به دست آوردن پوش طیفی

۴-۴-۴- نمایش مسئله آموزش شبکه عصبی RBF توسط الگوریتم IGPSO

به طور کلی، سه روش برای نمایش ترکیب پارامترهای مجهول وجود دارد: بردار، ماتریس و حالت باینری [۱۹]. در نمایش برداری، هر عنصر با یک بردار نمایش داده می‌شود. برای آموزش یک شبکه عصبی RBF، باید همه وزن‌ها، بایاس‌ها، پارامترهای انتشار و مراکز معلوم باشند. در نمایش ماتریسی، هر عنصر به صورت یک ماتریس نمایش داده می‌شود.


با کلاتر و ابعاد بالا مجموعه دادگان ورودی دسته‌بندی‌کننده می‌باشد. در این مقاله برای غلبه بر مشکل اول از شبکه عصبی RBF که دارای توانایی بالایی در دسته‌بندی دادگان است، استفاده گردید. برای حل مشکل دوم سعی شد برای آموزش دسته‌بندی‌کننده مبتنی بر RBF از الگوریتم IGPSO استفاده شود. نتایج حاصل از آزمایش الگوریتم ذکرشده بر روی توابع معیار نشان داد که الگوریتم IGPSO در حل مسائل با دادگان بالا نسبت به الگوریتم‌های معیار دیگر توانایی بسیار خوبی دارد. از طرف دیگر دسته‌بندی‌کننده مبتنی بر RBF و IGPSO در دسته‌بندی دادگان سوناری نتایج بسیار خوبی را نسبت به دسته‌بندی‌کننده‌های معیار دیگر ارائه نمود. نقطه‌ضعف این ترکیب افزایش پیچیدگی دسته‌بندی‌کننده طراحی‌شده می‌باشد. در کارهای آینده می‌توان از MLP برای کاهش پیچیدگی دسته‌بندی‌کننده حاصل استفاده کرد.

مراجع

- [۱] سیدمحمد رضا موسوی، محمد خویشه و مجید آقابابایی، مدل‌سازی و حذف کلاتر سونار فعال، انتشارات دانشگاه علوم دریایی امام خمینی (ره)، نوشهر، ۱۳۹۴.
- [2] M. R. Mosavi, M. Khishe, M. Aghababae, and F. Mohammadzadeh, "Approximation of active sonar clutter's statistical parameters using array's effective beam-width," *Iranian Journal of Marine Science and Technology*, vol. 73, no. 73, pp. 11-22, 2015.
- [3] S. Saremi, S. Mirjalili, and S. M. Mirjalili, "Chaotic krill herd optimization algorithm," *Procedia Technology*, vol. 12, pp. 180-185, 2014.
- [4] M. Mosavi, M. Khishe, and E. Ebrahimi, "Classification of sonar targets using OMKC, genetic algorithms and statistical moments," *Journal of Advances in Computer Research*, vol. 7, no. 1, pp. 143-156, 2016.
- [5] J. Kennedy, and R. Eberhart, "Particle swarm optimization," *IEEE Conference on Neural Network*, vol. 4, pp. 1942-1948, 1995.
- [6] S. Mirjalili, and A. Lewis, "S-shaped versus v-shaped transfer functions for binary particle swarm optimization," *Swarm and Evolutionary Computation*, vol. 9, pp. 1-14, 2013.
- [7] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey wolf optimizer," *Advances in Engineering Software*, vol. 69, pp. 46-61, 2014.
- [8] R. Hedayatzadeh, F. A. Salmassi, M. Keshtgari, and R. Akbari, "Termite colony optimization: A novel approach for optimizing continuous problems," *18th Iranian Conference on Electrical Engineering (ICEE)*, pp. 553-558, 2010.
- [9] S. Mirjalili, A. Lewis, and A. S. Sadiq, "Autonomous particles groups for particle swarm optimization," *Arabian Journal for Science and Engineering*, vol. 39, no. 6, pp. 4683-4697, 2014.

[۱۰] حسین شایقی و علی قاسمی، «پیش‌بینی قیمت روزانه برق با شبکه عصبی بهبودیافته مبتنی بر تبدیل موجک و روش آشوبناک جستجوی گرانشی»، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۵، شماره ۴، صفحات ۱۰۳-۱۱۳، ۱۳۹۴.

درنهایت، همگرایی نتایج برای انجام مقایسه‌ای جامع بررسی خواهد شد. نتایج در جدول ۹ نمایش داده شده است. از نقطه‌نظر آماری، الگوریتم IGPSO به‌اندازه کافی توانایی جلوگیری از گیر افتادن در حداقل‌های محلی را دارد و آهنگ همگرایی آن را می‌توان در شکل ۸ مشاهده کرد. همان‌گونه که در این شکل دیده می‌شود، الگوریتم IGPSO3 درنهایت به پایین‌ترین MSE در مقایسه با الگوریتم‌های دیگر دست می‌یابد. کارایی بهتر الگوریتم IGPSO در جستجوی همه فضای مسئله توسط گروه‌های مستقل است. به‌طوری‌که هر گروه با مقادیر اولیه مختلف، به‌صورتی متفاوت فضای مسئله را اکتشاف می‌کند. این امر باعث می‌شود که الگوریتم در کمینه‌های محلی گیر نکرده و از طرفی بار محاسباتی آن نیز افزایش نیابد. در جدول ۹ نیز مشاهده می‌شود که دسته‌بندی‌کننده مبتنی بر الگوریتم IGPSO2 به بالاترین نرخ دسته‌بندی دست پیدا می‌کند.



شکل ۸: نمودار همگرایی حاصل از دسته‌بندی‌کننده‌های مختلف بر روی دادگان سونار

جدول ۹: نتایج دسته‌بندی دادگان سونار با استفاده از شبکه عصبی RBF آموزش داده‌شده توسط الگوریتم‌های مختلف

الگوریتم	PSO	TACPSO	MPSO	IPSO	IGPSO1	IGPSO2	IGPSO3
نرخ دسته‌بندی	۹۲/۳۳۶	۹۳/۶۷۴۱	۹۱/۴۳۸	۹۲/۶۳۵	۹۴/۶۵۶۶	۹۶/۶۶۶۶	۹۵/۳۳۳۲

۵- نتیجه‌گیری

دسته‌بندی و تفکیک اهداف آشکارشده توسط سونار فعال (شامل هدف واقعی و کلاتر) دارای دو مشکل اساسی شباهت بسیار زیاد هدف واقعی

- on *Intelligent Systems Design and Applications*, vol. 2, pp. 638-643, 2008.
- [16] [http://archive.ics.uci.edu/ml/datasets/connectionist+bench+\(sonar,+mines+vs.+rocks\)](http://archive.ics.uci.edu/ml/datasets/connectionist+bench+(sonar,+mines+vs.+rocks)).
- [17] R. P. Gorman, and T. J. Sejnowski, "Analysis of hidden units in a layered network trained to classify sonar targets," *Neural Networks*, vol. 1, pp. 75-89, 1988.
- [18] M. R. Mosavi, M. Khishe, and A. Moridi, "Classification of sonar target using hybrid particle swarm and gravitational search," *Marine Technology*, vol. 3, no. 3, pp. 1-10, 2015.
- [19] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Let a biogeography-based optimizer train your multi-layer perceptron," *Information Sciences*, vol. 269, pp. 188-209, 2014.
- [20] S. Mirjalili, "How effective is the Grey Wolf optimizer in training multi-layer perceptrons," *Applied Intelligence*, vol. 43, no. 1, pp. 150-161, 2015.
- [11] G. G. Wang, A. H. Gandomi, and A. H. Alavi, "A chaotic particle-swarm krill herd algorithm for global numerical optimization," *Kybernetes*, vol. 42, no. 6, pp. 962-978, 2013.
- [۱۲] عقیل عبیری و محمدرضا محزون، «ردیابی اهداف متحرک هوایی با استفاده از تخمین چگالی کرنل بر اساس الگوریتم فیلتر ذره»، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۵، شماره ۳، صفحات ۹۷-۱۰۷، ۱۳۹۴.
- [13] T. Ziyu, and Z. Dingxue, "A modified particle swarm optimization with an adaptive acceleration coefficients," *Asia-Pacific Conference on Information Processing*, vol. 2, pp. 330-332, 2009.
- [14] G. Q. Bao, and K. F. Mao, "Particle swarm optimization algorithm with asymmetric time-varying acceleration coefficients," *IEEE Conference on Robotics and Biomimetics*, pp. 2134-2139, 2009.
- [15] Z. Cui, J. Zeng, and Y. Yin, "An improved PSO with time-varying accelerator coefficients," *IEEE Conference*

زیرنویس‌ها

¹ Particle Swarm Optimization

² Evolutionary Algorithms

³ Local Minima

⁴ Slow Convergence

⁵ Velocity

⁶ Weighting Function

⁷ Acceleration Coefficient

⁸ Echo

⁹ Wide-Band Linear FM

¹⁰ Overlearning

¹¹ Fitness Function

¹² Sum Squared Error (SSE)