

طراحی سامانه سوناری با قابلیت دسته‌بندی اهداف فعال و غیر فعال آکوستیکی مبتنی بر شبکه عصبی فرا ابتکاری

محمد خویشه^۱، احسان ابراهیمی^۲، افشین گلدانی^۳

۱-استادیار و ۲و۳- پژوهشگر، دانشگاه علوم دریایی امام خمینی (ره)، نوشهر، ایران

(دریافت: ۹۸/۰۲/۲۰، پذیرش: ۹۸/۰۹/۱۶)

چکیده

با توجه به اهمیت تعیین ماهیت اهداف سوناری در نبردهای دریایی، این مقاله به طراحی سامانه‌ای با قابلیت دسته‌بندی اهداف سوناری فعال و غیرفعال با استفاده از شبکه‌های عصبی پرسپترون چندلایه می‌پردازد. با توجه به نواقص پرسپترون‌های چندلایه در کار با داده‌های دنیای واقعی، این مقاله یک الگوریتم فرا ابتکاری جدید بانام بهینه‌ساز ازدحام ذرات با گروه‌های آشفته (CGPSO) را ارائه می‌دهد. این الگوریتم با استفاده از گروه‌های مجزای جستجو و همچنین نقشه‌های آشفته فضای جستجو را بهتر و سریع‌تر اکتشاف می‌کند. به منظور ارزیابی سامانه طراحی‌شده، یک مجموعه داده سوناری مرجع، یک مجموعه داده آزمایشگاهی غیرفعال و یک مجموعه داده واقعی فعال توسعه داده شد. به منظور داشتن یک مقایسه جامع سامانه طراحی‌شده با بهینه‌سازهای معیار ازدحام ذرات (PSO)، جغرافیایی زیستی (BBO) و گرگ خاکستری (GWO) از نظر سرعت همگرایی، دقت دسته‌بندی و قابلیت اعتماد مقایسه شد که سامانه طراحی‌شده نسبت به بهترین دسته‌بندی کننده موجود، به طور میانگین ۲/۳۳ درصد دقیق‌تر عمل کرد.

کلیدواژه‌ها: سونار، دسته‌بندی، پرسپترون چندلایه، بهینه‌ساز ازدحام ذرات با گروه‌های آشفته

Designing a Sonar System with the Ability of Classifying Active and Passive Acoustic Targets Based on the Evolutionary Neural Network

M. Khishe*, E. Ebrahimi, A. Goldani

Imam Khomeini Marine Science University of Nowshahr

(Received: 10/05/2019; Accepted: 07/12/2019)

Abstract

Considering the importance of identifying and determining the nature of the sonar targets in marine battles, the purpose of this paper is to design a system with the ability to classify active and passive sonar targets using multi-layer perceptron neural networks (MLP NNs). Considering the defects of MLP NNs in dealing with real-world data, as well as low classification accuracy and low convergence rate, this paper proposes a new meta-parasitic algorithm called Chaotic Groups Particles Swarm Optimizer (CGPSO) to train an MLP NN. This algorithm explores the search space faster and better than normal particle swarm Optimizer (PSO) using chaotic and independent groups. To evaluate the designed system, a benchmark sonar dataset, a passive laboratory data set and an active dataset were developed. In order to have a comprehensive comparison, the designed system was compared with PSO, biogeography-based Optimizer (BBO) and Gray Wolf Optimizer (GWO) in terms of convergence rate, classification accuracy, and reliability. Results show that the designed system was more accurate than the best available classifier, by average 2.33%.

Keywords: Sonar, Classification, Multi-layer Perceptron, Chaotic Particle Swarm Optimization

* Corresponding Author E-mail: m_khishe@alumni.iust.ac.ir

۱. مقدمه

[۱۶]، کلونی زنبور عسل مصنوعی (ABC) [۱۷]، بهینه‌ساز واکنش شیمیایی (CRO) [۱۸]، الگوریتم بهینه‌ساز مغناطیسی (MOA) [۱۹]، بهینه‌ساز نیروی مرکزی (CFO) [۲۰]، بهینه‌ساز دانه معکوس (IWO) [۲۱]، جستجوی سامانه متهم (CSC) [۲۲]، بهینه‌ساز اجتماع عنکبوت‌ها (SSO) [۲۳]، الگوریتم آموزش و یادگیری (TL) [۲۴]، بهینه‌ساز گرگ خاکستری (GWO) [۲۵]، بهینه‌ساز ازدحام ذرات (PSO) [۲۶]، الگوریتم جستجوی آینه (ISA) [۲۷]، بهینه‌ساز مبتنی بر جغرافیای زیستی (BBO) [۲۸ و ۲۹]، الگوریتم ترکیبی (PSO-GSA) [۳۰ و ۳۱] و الگوریتم جستجوی گرانشی (GSA) [۳۲] اشاره کرد.

هرکدام از این الگوریتم‌ها دارای نقاط ضعف و قوت مخصوص به خود هستند. یکی از عواملی که برای همه آن‌ها محدودکننده است، افزایش پیچیدگی نهایی سامانه و در نتیجه کاهش سرعت دسته‌بندی است؛ که با توجه به ابعاد بالای مجموعه داده‌های سوناری این موضوع تشدید می‌شود؛ بنابراین، استفاده از الگوریتم‌های بهینه‌ساز پیچیده هرچند باعث افزایش نرخ دسته‌بندی خواهد شد ولی ریسک خارج شدن سامانه از حالات بلادرنگ را به همراه خواهد داشت [۳۳].

با توجه به محدودیت ذکر شده و همچنین تئوری هیچ ناهاری مجانی نیست^{۱۵} (NFL) [۳۴] که اثبات می‌کند هیچ الگوریتم بهینه‌سازی وجود ندارد که برای همه مسائل بهترین جواب را ارائه کند، در این مقاله به جای استفاده از الگوریتم‌ها با پیچیدگی بالا از الگوریتم ساده بهینه‌ساز ازدحام ذرات (PSO) استفاده خواهد شد.

در الگوریتم PSO متعارف همه ذرات با یک توانایی در نظر گرفته شده و نحوی به‌روزرسانی مکان و سرعت آن‌ها نیز با یک راهبرد یکسان انجام خواهد شد. این در حالی است که در طبیعت موجودات مختلف دارای توانایی‌های متفاوت می‌باشند. از این‌روی در این مقاله از گروه‌های مختلف با راهبردهای به‌روزرسانی مختلف استفاده خواهد شد؛ همچنین برای افزایش دقت

با توجه به خصوصیات فیزیکی پیچیده محیط انتشار زیر سطح آب، طبقه‌بندی اهداف آکوستیکی به یک زمینه مهم و پرکاربرد برای محققان و صنعتگران فعال در این حوزه تبدیل شده است. سیگنال‌های ناخواسته در محیط زیرآب دارای منابع گوناگونی هستند که از جمله آن‌ها می‌توان به نویز، طنین و کلاتر اشاره کرد [۱]. با توجه به اینکه اکوهای حاصل از طنین دارای یک دامنه یکسان و همگن می‌باشند، باوجود اینکه از جنس پینگ ارسالی هستند، تمایز آن‌ها از هدف واقعی آسان است [۲]. هنگامی که جنس بستر دریا دارای تغییرات زیادی است و بستر با جنس‌های مختلفی وجود دارد، اکوهای برگشتی از بستر دارای ویژگی‌های هدف گونه خواهند بود، به‌صورتی که حتی تابع چگالی احتمال هدف واقعی و بستر بسیار باهم شبیه خواهند بود. این‌گونه اهداف کاذب را کلاتر می‌نامند [۳ و ۴]. طبقه‌بندی کلاتر و اهداف واقعی به خاطر تشابه بسیار زیاد اکوهای برگشتی از آن‌ها، کار بسیار دشواری است.


در سال‌های اخیر استفاده از شبکه‌های عصبی برای دسته‌بندی اهداف سوناری بسیار مرسوم شده است و تلاش‌های زیادی در این زمینه انجام گردیده است [۵-۷]. برای شبکه‌های عصبی مصنوعی چندلایه در بیشتر کاربردها از الگوریتم‌های پس انتشار بهینه‌شده [۸] و یا استاندارد [۹]، به‌عنوان روش یادگیری استفاده می‌گردد. روش‌های زیادی بر پایه مشتق‌گیری برای تعلیم شبکه عصبی شامل گرادینان نزولی [۱۰]، فیلتر کالمن [۱۱]، فیلتر کالمن تفکیک‌شده [۱۲] و پس‌انتشار [۱۳] استفاده شده‌اند. الگوریتم پس‌انتشار، بر مبنای گرادینان است که اشکالاتی همچون همگرایی آهسته و به‌کارگیری در یک محدوده کوچک را دارد و بنابراین، برای کاربردهای عملی قابل اعتماد نیست.

هدف نهایی فرآیند یادگیری در شبکه‌های عصبی، پیدا کردن بهترین ترکیب از یال‌ها و بایاس آن‌ها است به‌طوری‌که در آموزش شبکه و نمونه‌های آزمون، کمترین مقدار خطا را داشته باشیم. مرجع [۱۴] نشان می‌دهد که روش‌های بهینه‌سازی فرا ابتکاری می‌تواند جایگزین الگوریتم‌های یادگیری مبتنی بر گرادینان باشد، زیرا ماهیت تصادفی این الگوریتم‌ها باعث جلوگیری از گیر کردن در بهینه محلی، افزایش سرعت همگرایی و کاهش خطای دسته‌بندی می‌شود.

از جمله روش‌های فرا ابتکاری که در سال‌های اخیر برای آموزش شبکه‌های عصبی در حوزه اهداف سوناری استفاده شده‌اند می‌توان به الگوریتم ژنتیک (GA) [۱۵]، تبرید تدریجی (SA)^۱

^۲Artificial Bee Colony Algorithm^۳Chemical Reaction Optimization^۴Magnetic Optimization Algorithm^۵Central Force Optimization^۶Invasive Weed Optimization^۷Charged System Search^۸Social-Spider Optimization^۹Teaching-Learning-based Optimization Algorithm^{۱۰}Gray Wolf Optimizer^{۱۱}Particle Swarm Optimizer^{۱۲}Interior Search Algorithm^{۱۳}Biogeography-based Optimization Algorithm^{۱۴}Gravitational Search Algorithm^{۱۵}No Free Lunch^۱Simulated Annealing

$$S_j = \text{sigmoid}(s_j) = \frac{1}{(1 + \exp(-s_j))}, \quad j=1,2,\dots,h \quad (2)$$



شکل ۱. یک شبکه عصبی مصنوعی چندلایه با یک لایه پنهان [۳۰].

می‌توان بعد از محاسبه مقدار گره‌های پنهان، خروجی‌های نهایی را به صورت زیر تعریف نمود [۳۵]:

$$o_k = \sum_{j=1}^h (W_{jk} \cdot S_j) - \theta'_k, \quad k=1,2,\dots,m \quad (3)$$

$$O_k = \text{sigmoid}(o_k) = \frac{1}{(1 + \exp(-o_k))}, \quad k=1,2,\dots,m \quad (4)$$

که در آن، W_{jk} مبین وزن یال متصل‌کننده گره z_{am} (در لایه پنهان) به گره k_{am} (در لایه خروجی) و θ'_k مبین بایاس گره k_{am} (در لایه خروجی) است [۳۵]. مهم‌ترین بخش‌های شبکه‌های عصبی چندلایه، وزن یال‌ها و بایاس گره‌ها است. همان‌طور که در روابط بالا مشاهده گردید، وزن یال‌ها و بایاس‌ها، مقدار خروجی نهایی را تعریف کردند. آموزش یک شبکه عصبی چندلایه، شامل پیدا کردن بهترین مقدار برای وزن یال‌ها و بایاس‌ها، به منظور رسیدن به مقدار مطلوب خروجی در ازای ورودی‌های مشخص است.

۳. بهینه‌ساز ازدحام ذرات

بهینه‌ساز 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 به سوی بهترین ذره‌ای (بهترین راه‌حل) که در مسیرشان وجود دارد، حرکت می‌کنند. به عبارت دیگر، ذرات بهترین راه‌حل‌های خود را به عنوان بهترین راه‌حل کلی در نظر می‌گیرند. هر ذره در PSO باید پارامترهایی مانند موقعیت فعلی، سرعت فعلی، فاصله تا $pbest$ و فاصله تا $gbest$ را به منظور تغییر موقعیت خود در نظر بگیرد. مدل‌سازی ریاضی PSO به صورت روابط (۵) و (۶) است [۲۶].

دسته‌بندی بدون تحمیل افزایش پیچیدگی از نقشه‌های آشفته^۱ [۳۵] برای بهبود فاز اکتشاف و اجتناب از گیرکردن در بهینه‌های محلی به عنوان نوآوری اصلی مقاله استفاده خواهد شد. این الگوریتم را بهینه‌ساز ازدحام ذرات با گروه‌های مستقل آشفته (CGPSO)^۲ نام‌گذاری می‌شود.

در ادامه مقاله به منظور سنجش سامانه طراحی شده از سه مجموع داده سوناری استفاده خواهد گردید. مجموعه اول از مخزن UCI^۳ به عنوان یک مجموعه داده مرجع استخراج شده است [۳۶ و ۳۷] تا بتوان عملکرد الگوریتم را با روش‌های متعارف دیگر سنجید. همچنین به منظور ارزیابی عملکرد دسته بندی‌کننده طراحی شده در کار با دادگان واقعی و تجربی، دو مجموعه داده دیگر توسط نویسندگان توسعه داده خواهند شد [۳۸ و ۳۹].

سازمان‌دهی مقاله به این صورت است که بخش ۲ به معرفی شبکه‌های عصبی مصنوعی پرسپترون چندلایه خواهد پرداخت. بخش ۳ به بحث در خصوص بهینه‌ساز PSO و CGPSO می‌پردازد. شیوه اعمال الگوریتم CGPSO حاصل به عنوان یک الگوریتم آموزش فرا ابتکاری به شبکه‌های MLP در بخش ۴ توصیف گردیده است. مجموعه داده‌های سوناری در بخش ۵ و نتایج در بخش ۶ مورد بحث قرار خواهند گرفت و در نهایت در بخش ۷ نتیجه‌گیری بیان خواهد شد.

۲. شبکه عصبی چندلایه

شکل (۱) یک شبکه عصبی MLP (۳ لایه) را نشان می‌دهد که در آن، n مبین تعداد گره‌های ورودی، h مبین تعداد گره‌های پنهان و m مبین تعداد گره‌های خروجی است. همان‌طور که ملاحظه می‌شود، اتصال‌های یک‌طرفه بین گره‌های شبکه عصبی چندلایه که از خانواده شبکه‌های عصبی FNN است، وجود دارد. خروجی شبکه عصبی چندلایه به صورت رابطه (۱) محاسبه می‌گردد [۲۸]:

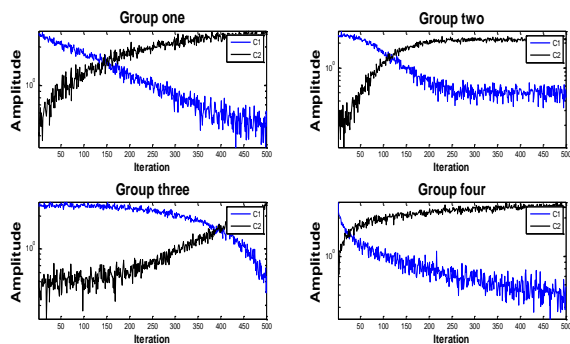
$$s_j = \sum_{i=1}^n (W_{ij} \cdot X_i) - \theta_j, \quad j=1,2,\dots,h \quad (1)$$

که در آن، n مبین تعداد گره‌های ورودی، W_{ij} مبین وزن یال متصل‌کننده گره z_{am} (در لایه ورودی) به گره z_{am} (در لایه پنهان)، θ_j مبین بایاس گره z_{am} (در لایه پنهان) و X_i مبین ورودی به گره z_{am} (در لایه ورودی) است. خروجی هر گره پنهان با استفاده از یک تابع سیگموئید و به صورت رابطه (۲) به دست می‌آید [۳۵]:

¹ Chaotic Maps
² Chaotic Group Particle Swarm Algorithm
³ University of California, Irvine

به‌دست آورد. در این الگوریتم، گروه‌های مستقل توسط روابط ارائه‌شده در [۲۶] برای به‌روزرسانی C_1 و C_2 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. به‌منظور افزایش توانایی الگوریتم در فاز بهره‌برداری و جلوگیری از همگرایی زودرس از نقشه‌های آشفته برای افزایش توانایی اجتناب از بهینه محلی استفاده شده است. این راهبردهای به‌روزرسانی در جدول (۱) و شکل (۲) نمایش داده شده‌اند.



شکل ۲. نمایش ضرایب به‌روزرسانی آشفته

در CGPSO ابتدا همه ذرات به‌صورت تصادفی در فضای جستجوی مسئله قرار می‌گیرند. پس از آن ذرات به‌طور تصادفی به برخی گروه‌های مستقل از پیش تعریف شده تقسیم می‌گردند. در هر تکرار $gbest$ ، $pbest$ 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 (۵) و (۶) به‌روزرسانی می‌شوند. بلوک دیاگرام کلی الگوریتم پیشنهادی در شکل (۳) نمایش داده شده است.

$$v_i^{t+1} = w v_i^t + c_1 \times rand \times (pbest_i - \chi_i^t) + c_2 \times rand \times (gbest - \chi_i^t) \quad (5)$$

$$\chi_i^{t+1} = \chi_i^t + v_i^{t+1} \quad (6)$$

در روابط بالا v_i^t مبین سرعت^۱ ذره i در تکرار t ام، w مبین تابع وزن^۲، C_2 مبین ضریب شتاب^۳ و $rand$ نشان‌دهنده یک عدد تصادفی بین ۰ و ۱ است. χ_i^t مبین موقعیت فعلی ذره i ام در تکرار t ام است. همچنین $pbest_i$ ، بهترین راه‌حل عامل i ام در تکرار t ام است و بهترین راه‌حلی که تاکنون پیدا شده است، $gbest$ است [۲۶].

۳-۱. الگوریتم بهینه‌ساز ازدحام ذرات با گروه‌های مستقل آشفته

مفهوم گروه‌های مستقل با الهام 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 وظایفشان را به‌عنوان عضوی از گروه انجام می‌دهند. توانایی هر فرد می‌تواند در یک 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 [۲۶].

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. با این حال به لحاظ 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

جدول ۱. راهبردهای به‌روزرسانی با الگوی گروه‌های مستقل چهارگانه و آشفته

C_1	C_2	گروه
Chaotic-Value*2.5-(2log(t)/log(T))	Chaotic-Value* (2log(t)/log(T)) + 0.5	۱
Chaotic-Value* (-2t ³ /T ³) + 2.5	Chaotic-Value* (2t ³ /T) + 0.5	۲
Chaotic-Value*0.5 + 2exp[-(4t/T) ²]	Chaotic-Value*2.2-2exp[4t/T] ²	۳
Chaotic-Value*2.5 + 2(t/T) ² - 2(2t/T)	Chaotic-Value*0.5-2(t/T) ² + 2(2t/T)	۴

¹ Velocity

² Weighting Function


³ Acceleration Coefficient

الگوریتم آموزش‌دهنده برای شبکه‌های عصبی چندلایه، لازم است وزن یال‌ها و بایاس گره‌ها به صورت مناسب نمایش داده شوند.

به‌طورکلی سهرامه برای نشان دادن وزن یال‌ها و بایاس گره‌ها وجود دارد که عبارت‌اند از: بردار، ماتریس و روش دودویی. در بردار، ماتریس و روش دودویی، به ترتیب هر عنصر با یک بردار، ماتریس و رشته‌ای از بیت‌های دودویی نشان داده می‌شود. هرکدام از این روش‌ها دارای مزایا و معایبی هستند که ممکن است در موارد خاص مفید است.

در روش نخست، تبدیل عناصر به بردار، ماتریس و یا رشته‌ای از بیت‌های باینری آسان است، اما فرآیند بازیابی آن‌ها پیچیده خواهد بود. به همین دلیل اغلب این روش در شبکه‌های عصبی ساده مورداستفاده 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 چندلایه پیچیده سروکار نداریم، از روش برداری استفاده شده است. به‌عنوان مثالی از این شیوه کد نویسی، بردار نهایی شبکه عصبی چندلایه نشان داده شده در شکل (۴)، در رابطه (۷) آورده شده است.

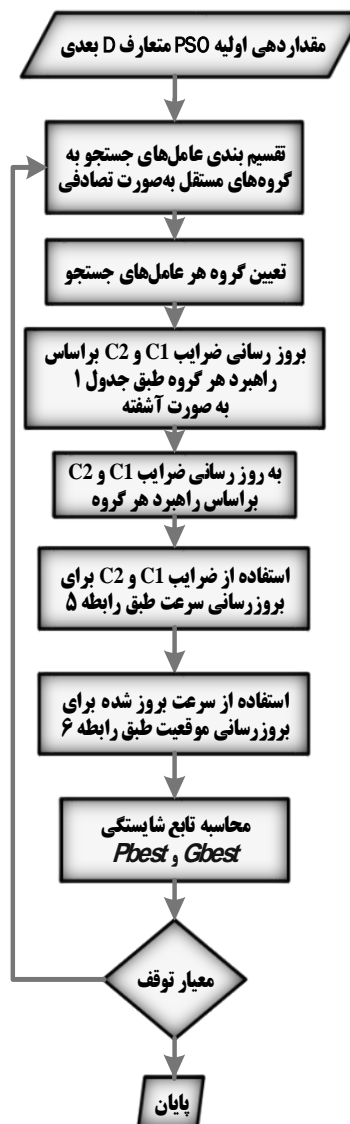


شکل ۴. شبکه عصبی چندلایه با ساختار ۱-۳-۲

$$Position = [w_{13} w_{23} w_{14} w_{24} w_{15} w_{25} w_{36} w_{46} w_{56} \theta_1 \theta_2 \theta_3 \theta_4] \quad (7)$$

۵. مجموعه دادگان سونار

راهبرد اصلی در این مقاله استفاده از سه مجموعه دادگان به صورت ذیل است:



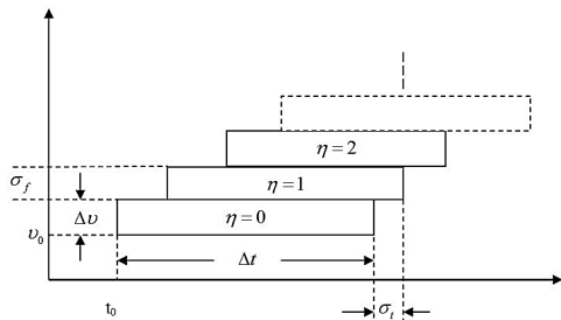
شکل ۳. بلوک دیاگرام کلی الگوریتم پیشنهادی

۴. آموزش یک شبکه عصبی چندلایه با استفاده از


الگوریتم CGPSO

به‌طورکلی، سه روش استفاده از الگوریتم‌های تکاملی برای آموزش شبکه‌های عصبی چندلایه وجود دارد. اولین روش عبارت است از به‌کارگیری شبکه‌های تکاملی به منظور یافتن ترکیب وزن یال‌ها و بایاس گره‌ها برای داشتن کمترین مقدار خطا در یک شبکه عصبی چندلایه. دومین شیوه عبارت است از به‌کارگیری شبکه‌های تکاملی به منظور یافتن ساختار مناسب شبکه عصبی چندلایه در یک مسئله خاص و آخرین شیوه شامل به‌کارگیری شبکه‌های تکاملی به منظور یافتن پارامترهای الگوریتم یادگیری مبتنی بر گرادینان از قبیل نرخ یادگیری و اندازه حرکت است. در این مقاله، الگوریتم CGPSO، با استفاده از شیوه نخست به یک شبکه عصبی MLP اعمال می‌گردد. به منظور طراحی یک

همان‌گونه که در شکل (۶) نمایش داده شده است، در این آزمایش پوش طیفی از ۶۰ نمونه طیفی که بین ۰ و ۱ نرمالیزه شده‌اند، تشکیل شده است. هر کدام از این اعداد نماینده مجموع انرژی موجود در درجه نمونه برداری مربوطه است؛ به‌طور مثال انرژی موجود در درجه اول ($\eta = 0$) بعد از نرمالیزه شدن، عدد اول از ۶۰ عدد موجود در بردار ویژگی را تشکیل می‌دهد.



الف) درجه‌های نمونه برداری



ب) اعمال مجموعه درجه‌های نمونه برداری بر روی طیف‌نگار دوبعدی

شکل ۶. پیش پردازش استفاده شده برای به دست آوردن پوش طیفی

۲-۵. مجموعه دادگان غیرفعال (تونل کاویتاسیون)

برای انجام این آزمایش و به دست آوردن مجموعه دادگان قابل اطمینان در مرحله اول سه نوع پروانه در کلاس‌های A، B و C دریایی ساخته شد. جزییات و مشخصات در مرجع [۳۳] توضیح داده شده است. سپس (به منظور شبیه سازی شرایط کاری شناورهای مختلف) مورد بررسی قرار گرفتند. در طول این آزمایش‌ها، صوت (نویز آکوستیکی) حاصل از پروانه‌های مختلف توسط هیدروفون و برد جمع آوری داده در رایانه ذخیره گردید. در این آزمایش از برد جمع آوری داده مدل UDAQ_Lite ساخت شرکت Eagle Technology کشور آفریقای جنوبی استفاده شده است. مشخصات تونل در جدول (۲) نمایش داده شده است.

سرعت پیشروی پروانه در آب‌های آزاد به صورت عددی بدون بعد J متناسب با سرعت چرخش N (RPM) و یا سرعت چرخش در ثانیه n (RPS) و قطر پروانه D (m) و سرعت جریان آب بیان طبق رابطه (۸) می‌شود [۳۳].

• مجموعه دادگان Sejnowski&Gorman به منظور داشتن یک مجموعه دادگان مرجع برای مقایسه دسته بندی کننده‌های پیشنهادی با کارهای محققان دیگر [۳۶].


• طراحی سناریو آزمایش و جمع آوری مجموعه دادگان در تونل کاویتاسیون دانشگاه علوم دریایی امام خمینی (ره) برای استفاده به منظور مجموعه دادگان غیرفعال سوناری.

• طراحی سناریو آزمایش و جمع آوری مجموعه دادگان توسط سونوبوی طراحی شده در دانشگاه علوم دریایی امام خمینی (ره) برای استفاده به منظور مجموعه دادگان فعال سوناری.

در ادامه، مجموعه دادگان ذکر شده به‌طور مختصر شرح داده خواهد شد.

۱-۵. مجموعه دادگان Sejnowski&Gorman

دادگان سونار مورداستفاده در این قسمت، از آزمایش Gorman و Sejnowski موجود در مراجع [۳۶ و ۳۷] استخراج شده است. در این آزمایش دو نوع اکو^۱ (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. 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^۲ ($ka=55/6$) به سمت آن‌ها فرستاده شده است. بر اساس SNR اکوی دریافتی، از ۱۲۰۰ اکو جمع آوری شده، ۲۰۸ اکو که SNR آن‌ها بین 4dB تا 15dB است، انتخاب شده‌اند. از این ۲۰۸ اکو، ۱۱۱ عدد مربوط به سیلندر فلزی و ۹۷ عدد مربوط به صخره هستند. شکل (۵) نمونه‌هایی از اکوهای دریافتی از صخره و سیلندر فلزی را نشان می‌دهد. مشاهده می‌شود که اکوهای هدف واقعی (سیلندر فلزی) و کلاتر (صخره) بسیار شبیه هم است و با یک دسته بندی کننده خطی یا غیرخطی مرتبه پایین نمی‌توان آن‌ها را از یکدیگر تفکیک کرد.



شکل ۵. نمونه‌ای از اکوهای بازگشتی از صخره و سیلندر فلزی در مراجع [۳۶ و ۳۷]

³ Data-Logger

¹ Echo

² Wide-Band Linear FM

قابل قبولی از این نویزها داشته باشیم. در مرحله سوم پروانه در دوره‌های مختلف (متناسب با نوع شناور مدل شده) به چرخش درآمده تا نویزهای مربوط به چرخش پروانه برای کلاس‌های مختلف شناور به دست آید. در مرحله چهارم با روشن نمودن پمپ چرخش آب و پمپ تخلیه حباب‌های درون تونل تخلیه و سپس موتور پروانه فعال شده و صوت حاصل توسط برد جمع‌آوری داده و نرم‌افزار مطلب در رایانه ذخیره می‌شود. در تمامی مراحل داده‌های واقعی بدون تقویت مقادیر، در رایانه ذخیره شده تا در مراحل بعد از این مقادیر استفاده شود.

۵-۲-۱. ترسیم منحنی‌های نویز برای پروانه‌های مدل

با توجه استاندارد مراجع (۴۱ و ۴۲) توان برحسب dB نسبت به توان مرجع صوتی آب (1μPa) محاسبه می‌گردد. شکل (۸) از چپ به راست به ترتیب منحنی‌های نویز دریافتی در سطح هیدروفن، تبدیل فوریه و طیف توان نویز برحسب دسی‌بل را برای شناورهای مدل شده مختلف نشان می‌دهد.

$$J = \frac{v}{nD} \quad (8)$$


در کلیه آزمایش‌ها فشار اتمسفر ۱۰۰ kpa و فشار داخل تونل با توجه به عمق قرارگیری پروانه در آن کلاس شناور متغیر در نظر گرفته شده است. همچنین سرعت جریان آب در داخل تونل ۴m/s است.

یکی از هیدروفن‌ها در کنار پروانه در فاصله ۱۰ سانتی‌متری و دیگری در فاصله ۵۰ سانتی‌متری از هیدروفن اول مطابق شکل (۷) نصب شده است

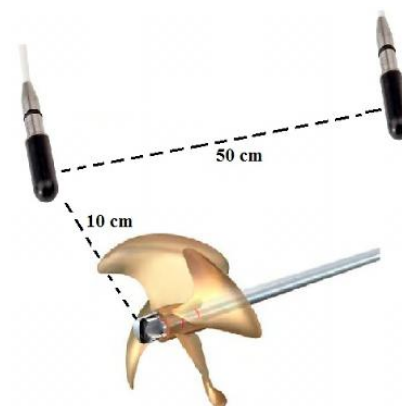
در این قسمت اندازه‌گیری نویز پروانه‌های طراحی شده طی چهار مرحله انجام می‌شود. در مرحله اول بعد از آرامش جریان آب، نویز موجود توسط هیدروفن‌ها دریافت و سپس توسط برد جمع‌آوری داده و نرم‌افزار مطلب دریافت و ذخیره می‌شود. در مرحله دوم با روشن نمودن موتور رانش پروانه و بدون چرخ پروانه در چندین مرحله نویز موتور نیز دریافت می‌شود تا بتوان تخمین

جدول ۲. مشخصات تونل کاویتاسیون

مدل تونل	مدل NA10 ساخت انگلستان	ضریب پیشروی	۰/۱ الی ۰/۹
ابعاد مقطع شیشه‌ای	ارتفاع ۲۰۰-عرض ۲۰۰-طول ۷۵۰ میلی‌متر	ابعاد تونل	ارتفاع ۲۷۵۰-طول ۴۹۰۰-عرض ۱۱۰۰ میلی‌متر
سرعت آب در تونل	حداقل ۰/۶۵ و حداکثر: ۴/۸ (متر بر ثانیه)	عدد کاویتاسیون	۲ الی ۵
گشتاور موتور پروانه	صفر الی ۱۴۰ نیوتن متر	محدوده فشار	۵۰ الی ۲۰۰ کیلو پاسکال
سرعت چرخش پروانه	حداکثر ۳۰۰۰ دور بر دقیقه	پمپ اصلی	۵/۵ کیلووات-۳۸۰:۴۴۰ ولت-سه‌فاز-۵۰ هرتز

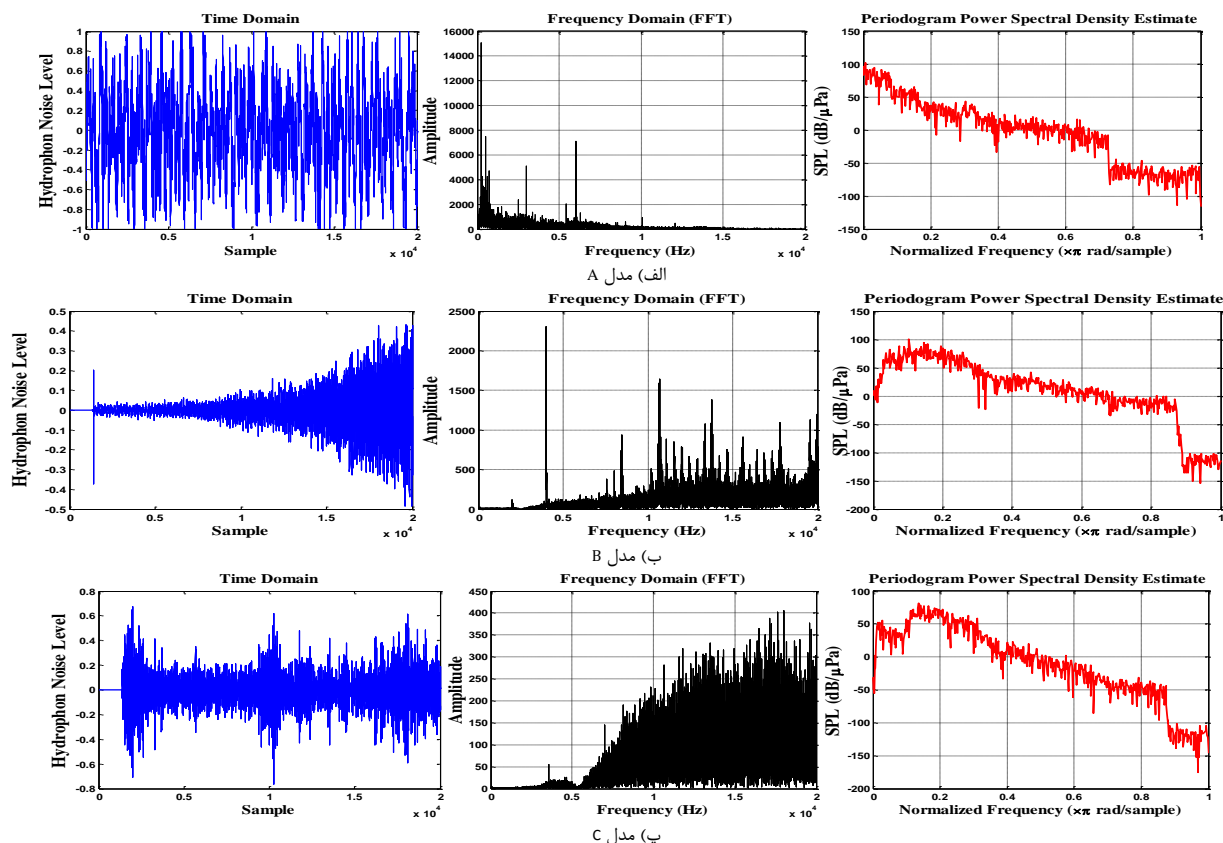


ب) تونل کاویتاسیون، پروانه و هیدروفن‌ها در قسمت Section Test



الف) موقعیت پروانه و هیدروفن‌ها

شکل ۷. تونل کاویتاسیون و موقعیت نصب هیدروفن‌ها نسبت به پروانه در تونل



شکل ۸. از چپ به راست به ترتیب منحنی‌های نویز دریافتی در سطح هیدروفون، تبدیل فوریه و طیف توان نویز برحسب دسی‌بل نسبت به توان مرجع صوتی آب ($1/Pa$) برای پروانه‌های مدل مختلف.

فرکانسی ۵-۱۱۰ هرتز را پوشش می‌دهد. اهداف قرار داده شده در کف توسط یک موتور الکتریکی به اندازه ۱۸۰ درجه و با دقت یک درجه چرخانده می‌شوند. در این حالت اکوهای برگشتی در فاصله ۱۰ متری از آن‌ها جمع‌آوری شده است.

تنها تفاوت عمده دادگان به‌دست‌آمده در تونل کلویتاسیون با دادگان جمع‌آوری شده در شرایط واقعی، متغیر بودن SPL دریافتی در محیط واقعی است. این متغیر بودن SPL به دلیل متغیر و ناهمگن بودن محیط انتقال صوت در دریا است.

۵-۳. مجموعه دادگان فعال (سونوبوی)

مجموعه دادگان فعال مورد استفاده در این مقاله از آزمایش صورت گرفته در سواحل نوشهر به‌دست‌آمده است. این منطقه با عمق بین ۴۰ تا ۱۰۰ متر جزو مناطق کم‌عمق^۱ است. این دادگان توسط سونوبوی نشان داده شده در شکل (۹-الف) جمع‌آوری شده است [۳۹]. همچنین اطلاعات مربوط به پارامترهای محیطی مانند دما، شوری، عمق آب، سرعت وزش باد، جنس کف دریا و غیره از بویه موج‌نگار سازمان بنادر و دریانوردی نوشهر که در شکل (۹-ب) نمایش داده شده است، به‌دست‌آمده است.

در این آزمایش ۶ شیء شامل ۴ هدف^۲ و ۲ غیر-هدف^۳ در بستر شنی دریا قرار داده شده‌اند. در این آزمایش سیگنال ارسالی یک پالس چیرپ مدوله شده خطی پهن باند است که بازه



شکل ۹. سونوبوی‌های مورد استفاده برای به‌دست آوردن مجموعه دادگان سوناری (الف) سونوبوی برای ارسال پینگ و دریافت باز پراکنش اهداف (ب) سونوبوی تأمین‌کننده اطلاعات محیطی


یک مجموعه دادگان خوب نقش بسیار حیاتی را در دسته‌بندی دادگان سوناری ایفا می‌کند. با توجه به حجم بالای دادگان خام

¹ shallow water
² Target
³ Non-Target


$$H(k) = \frac{X(k)}{|X(k)|^2 + c} \quad (9)$$

که در این رابطه، $X(k)$ تبدیل فوریه سیگنال ارسالی و $c = 0.0025 \text{Max}(|X(k)|^2)$ برای حل مشکل یکتایی به رابطه اضافه می‌شود. خروجی این مرحله سیگنال تفرق خالص بدون اثرات پدیده‌های مصنوعی است.


۴. **نرمالیزه کردن:** در نهایت هر هدف را به گونه‌ای مقیاس می‌کنیم که هر کدام قدرت هدف یکسانی داشته باشند. برای این کار هر سیگنال تفرق را توسط SAR¹ که بزرگ‌ترین دامنه‌ای که از ۹۰٪ حداکثر دامنه‌های دریافتی کمتر است، تقسیم می‌شود. در شکل (۱۰) نمونه‌های از سیگنال‌های دریافتی از اهداف مختلف که تابعی از فرکانس و جهت اهداف است، نمایش داده شده است.




الف) هدف شماره ۱




ب) هدف شماره ۳




ث) غیر-هدف شماره ۱



ب) هدف شماره ۲



ت) هدف شماره ۴



ج) غیر-هدف شماره ۲

شکل ۱۰. نمونه‌ای از اکوهای برگشتی از اشیای مختلف شامل هدف و غیر-هدف

به دست آمده در مرحله قبل، حجم محاسبات بالا مورد انتظار خواهد بود. به منظور کاستن از بار محاسباتی دسته‌بندی کننده و استخراج کننده ویژگی، فرآیند آشکارسازی اهداف محتمل از کل داده دریافتی لازم و ضروری است. بدین منظور از شدت سیگنال دریافتی استفاده می‌شود.


به دلیل عمق کم دریا در این محیط پدیده‌های از قبیل انتشار چندمسیرگی، انعکاس‌های چندگانه و طنین غیرقابل اجتناب هستند. بعد از مرحله آشکارسازی و قبل از مرحله استخراج ویژگی، با استفاده از یک فیلتر در حوزه فیلترهای تطبیقی به حذف اثرات این پدیده‌های مصنوعی می‌پردازیم. بعد از این مرحله با استفاده از فیلترینگ معکوس به بازبانی سیگنال بازتابش اصلی می‌پردازیم. در این مرحله از این حقیقت استفاده شده است که جداسازی این پدیده‌های مصنوعی در حوزه فیلتر تطبیقی بسیار ساده‌تر از حوزه زمان است. کل فرآیند پیش پردازش در چهار مرحله به شرح ذیل انجام می‌شود:

۱. **مقیاس گذاری:** به منظور حذف اثر بهره تقویت کننده، فیلتر و غیره در مرحله جمع‌آوری داده، سیگنال خام را به سیگنال مقیاس‌دهی شده تبدیل می‌کند.

۲. **نمونه برداری گاهنده:** نرخ نمونه برداری اصلی ۲ MHz است که از پهنای باند سیگنال اصلی بسیار بیشتر است. به منظور کاهش نرخ نمونه برداری به صورتی که اطلاعات مفید از دست نرود از مرجع [۳۸] استفاده شده است. در این مرجع با استفاده از اطلاعات محیطی مانند عمق آب، فرکانس کاری، ناحیه تحت پایش و غیره برای هر پینگ تعداد نقاط ثابتی در مرحله نمونه برداری انتخاب می‌شود. در اینجا ۲۰۴۸ نقطه انتخاب می‌شود به صورتی که اطلاعات مفید برای استخراج ویژگی از بین نرود.

۳. **فرآیند حذف مصنوعات و چندمسیرگی:** در این روش با استفاده از همبستگی متقابل سیگنال تفرق با سیگنال ارسالی در هر زاویه، مکان حداکثر خروجی فیلتر تطبیقی بانام x مشخص می‌شود. سپس یک پنجره که محدوده $[x-left, x+right]$ را پوشش می‌دهد، بر روی سیگنال اعمال می‌شود. در این $right$ برابر با ۳۰۰ و $left$ مساوی با ۲۱۱ است که تشکیل یک پنجره ۵۱۲ نقطه‌ای را می‌دهد. به منظور حفظ اندازه اصلی سیگنال، این سیگنال بخش بندی شده صفر پر شده و برای حذف اثر سیگنال ارسالی توسط رابطه (۹) فیلتر معکوس می‌شود [۲۹].

¹ Signal Reference Amplitude



شکل ۱۲. بلوک دیاگرام استخراج ویژگی

۶. نتایج و بحث

در این بخش توانایی الگوریتم CGPSO در دسته‌بندی داده‌ها سوناری مورد آزمایش قرار می‌گیرد. معیارهای مقایسه دقت دسته‌بندی، یافتن کمینه محلی و سرعت همگرایی می‌باشند. ابعاد مجموعه دادگان فراهم‌شده در جدول (۳) و ضرایب الگوریتم CGPSO و الگوریتم‌های معیار در جدول (۴) نمایش داده‌شده است. در تمامی الگوریتم‌ها وزن اینرسی w برای همه الگوریتم‌های مبتنی بر PSO به‌طور خطی از ۰/۹ تا ۰/۴ کاهش می‌یابد. همچنین تعداد ذرات موجود ۱۰۰ عدد و حداکثر تعداد تکرارها ۵۰۰ است.


جدول ۳. دادگان مورد استفاده در مقاله

نام مجموعه دادگان	تعداد مثال	تعداد ویژگی	تعداد نمونه آموزش (Train)	تعداد نمونه آزمون (Test)	تعداد نمونه اعتبارسنجی (Validation)
فعال (سونوبوی)	۳۰۰	۱۳	۲۱۰	۶۰	۳۰
غیرفعال (کاویتاسیون)	۴۸۰	۱۲۰	۳۳۶	۹۶	۴۸
Sejnowski&Gorman	۲۰۸	۶۰	۱۴۵	۴۳	۲۰

جدول ۴. پارامترها و مقادیر اولیه مربوط به الگوریتم‌های مورد استفاده

الگوریتم	پارامترها	مقادیر
PSO	مکان‌شناسی	اتصال کامل
	ضریب شناختی (C ₁)	۱
	ضریب اجتماعی (C ₂)	۱
	ثابت وزن (w)	۰/۳
	بیشینه تعداد تکرار	۵۰۰
GSPSO	اندازه جمعیت	۲۰۰
	ضریب شناختی (C ₁)	مطابق جدول (۱)
	ضریب اجتماعی (C ₂)	مطابق جدول (۱)
GWO	بیشینه تعداد تکرار	۵۰۰
	تعداد گرگ‌ها	۱۲
	محدوده پایین	-۵
	محدوده بالا	۵
	بیشینه تعداد تکرار	۵۰۰

تمامی قسمت‌های مرحله پیش‌پردازش به‌صورت بلوکی در شکل (۱۱) نمایش داده‌شده است.



شکل ۱۱. نمایش بلوکی بخش پیش‌پردازش

۴-۵. استخراج ویژگی

بعد از بخش پیش‌پردازش و دریافت فریم‌های آشکارشده که حاوی صوت مربوط به سیگنال‌های تفرق هستند، در این مرحله صوت‌های آشکارسازی شده که اثرات پدیده‌های مصنوعی آن‌ها حذف شده و به حوزه فرکانس برده شده است (بانام S(k) به بخش استخراج ویژگی تحویل داده می‌شود. در این مرحله در ابتدا انرژی طیف سیگنال توسط رابطه (۱۰) محاسبه می‌شود [۲۶]:

$$|S(k)|^2 = S_r^2(k) + S_i^2(k) \quad (10)$$

که در این رابطه $S_r(k)$ و $S_i(k)$ به ترتیب قسمت حقیقی و موهومی تبدیل فوریه سیگنال آشکارسازی شده هستند. سپس انرژی طیفی $|S(k)|^2$ توسط M فیلتر سه‌گوش مقیاس Mel فیلتر می‌شود. انرژی خروجی l-امین فیلتر توسط رابطه (۱۱) به‌دست می‌آید [۲۹].

$$E(l) = \sum_{k=0}^{N-1} |S(k)|^2 H_l(k) \quad (11)$$

در این رابطه N تعداد فرکانس‌های گسسته است که در تبدیل FFT مرحله پیش‌پردازش استفاده شده بود و $H_l(k)$ تابع انتقال فیلتر داده‌شده است به صورتی که $0, 1, \dots, Ml =$ محدوده پویایی طیف انرژی فیلتر شده در مقیاس Mel توسط تابع لگاریتم به‌صورت رابطه (۱۲) فشرده می‌شود.

$$e(l) = \log(E(l)) \quad (12)$$

در نهایت ضرایب ادراکی فرکانس Mel (MFCC) به‌وسیله رابطه (۱۳) و تبدیل کسینوسی گسسته (DCT) به حوزه زمان بازگردانده می‌شود [۲۹].

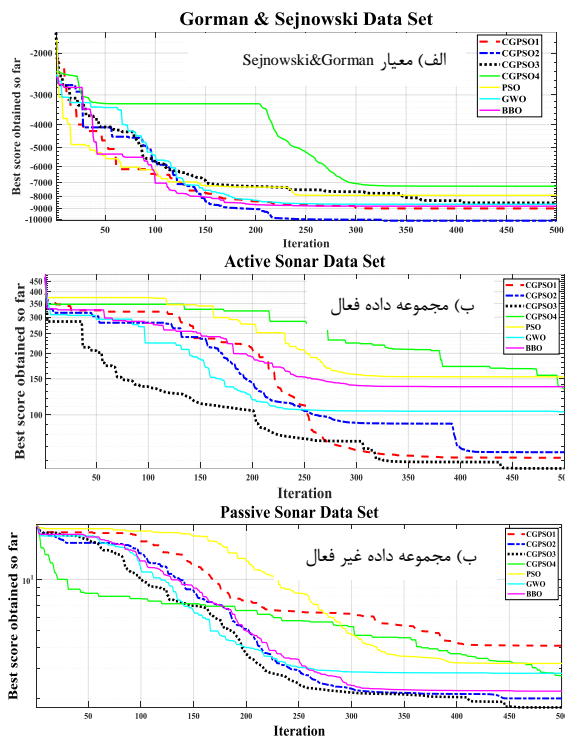
$$c(n) = \sum_{l=1}^M e(l) \cos(n(l-0.5)\frac{\pi}{M}) \quad (13)$$

در این حالت و برای هر هدف آشکارشده، بردار ویژگی به‌صورت رابطه (۱۴) خواهد بود.

$$X_m = [c(0), c(1), \dots, c(P-1)]^T \quad (14)$$

تمامی مراحل ذکر شده در مرحله استخراج ویژگی به‌صورت بلوکی در شکل (۱۲) نمایش داده‌شده است.

همان‌طور که از این جدول قابل مشاهده است، CGPSO3 و CGPSO2 بهترین نتایج را دارا هستند. این نتایج نشان می‌دهد که گروه‌های مستقل و نقشه‌های آشفته می‌توانند عملکرد الگوریتم PSO را برای این مسائل بهبود بخشند. شکل (۱۲) منحنی‌های همگرایی الگوریتم‌ها را نشان می‌دهد.



شکل ۱۳. نمودار همگرایی الگوریتم‌های مختلف در دسته‌بندی اهداف سوناری (الف) معیار (ب) فعال (پ) غیرفعال

همان‌طور که می‌توان از این منحنی مشاهده کرد، CGPSO3 و CGPSO2 از بهترین نرخ‌های همگرایی برای هر سه مجموعه داده و CGPSO1 برای دو مجموعه داده برخوردار هستند. نتایج حاصل از الگوریتم‌های CGPSO نشان می‌دهد که گروه‌های مستقل می‌توانند توانایی همگرایی الگوریتم PSO را به‌طور قابل‌توجهی بدون اینکه پیچیدگی الگوریتم افزایش یابد، بهبود بخشند. دلیل برتری نتایج این است که ذرات از تنوع جمعیتی برخوردارند و به‌طور مؤثر قادر به بهره‌برداری از دانش محلی در نزدیکی راه‌حل‌های بهینه هستند و در بهینه‌های محلی گیر نمی‌کنند.

۶-۲. سنجش عملکرد بلادرنگ دسته‌بندی‌کننده طراحی‌شده

پس از طراحی کل سامانه دسته‌بندی‌کننده مبتنی بر شبکه‌های عصبی فرا ابتکاری، به‌منظور پردازش بلادرنگ تصمیم بر پیاده‌سازی سخت‌افزاری آن بر بستر تراشه FPGA گرفته شد. بدین منظور دسته‌بندی‌کننده طراحی‌شده در محیط Xilinx System Generator (XSG) پیاده‌سازی گردید. قسمت

در دسته‌بندی مجموعه‌های داده، تعداد گره ورودی برابر با تعداد ویژگی‌های صوت ورودی و تعداد گره پنهان برابر با تعداد دسته مورد انتظار است. از آنجایی که برای انتخاب تعداد گره‌های لایه پنهان استاندارد وجود ندارد، بنابراین، بر اساس ساختار شبکه‌های عصبی چندلایه، از پیشنهاد مطرح‌شده در [۳۸] و از رابطه (۱۵) استفاده خواهد شد.

$$H = 2 \times N + 1 \quad (15)$$

که در آن، N مبین تعداد ورودی‌ها و H مبین تعداد گره‌های پنهان را نشان می‌دهد.

۶-۱. تجزیه و تحلیل عملکرد

برای مقایسه عملکرد تمامی الگوریتم‌ها، میانگین نتایج بیش از ۱۰ اجرا جمع‌آوری شده است. میانگین بهترین راه‌حل‌ها (نشان‌دهنده دقت دسته‌بندی) و همچنین میانگین و انحراف معیار میزان خطا (نشان‌دهنده توانایی الگوریتم در اجتناب از بهینه محلی) در جدول (۵) و نمودار همگرایی الگوریتم‌های مختلف در شکل (۱۳) برای سه مجموعه داده‌گان سونار معیار، فعال و غیرفعال نمایش داده شده است. در جدول (۵) بهترین نتایج با رنگ سیاه مشخص شده است.

جدول ۵. میانگین بهترین راه‌حل‌ها و همچنین میانگین و انحراف معیار میزان خطا

دادگان	الگوریتم	MSE(AVE±STD)	میانگین دقت دسته‌بندی (درصد)
Sejnowski&Gorman	CGPSO1	۰/۰۰۰۵±۰/۰۴۹۱	۸۵/۳۲۵۴
	CGPSO2	۰/۰۰۰۲±۰/۰۷۰۰	۸۸/۲۵۴۸
	CGPSO3	۰/۰۰۱۵±۰/۰۷۲۱	۸۴/۲۵۴۷
	CGPSO4	۰/۰۷۱۵±۰/۰۰۱۲	۷۹/۷۸۹۵
	PSO	۰/۰۰۱۱±۰/۰۷۲۸	۸۰/۲۵۴۶
	GWO	۰/۰۰۱۴±۰/۰۱۹۱	۸۵/۸۴۵۶
	BBO	۰/۰۰۱۵±۰/۰۳۷۱	۸۶/۸۵۴۲
فعال	CGPSO1	۰/۰۰۰۵±۰/۰۷۳۲	۹۳/۹۳۷۴
	CGPSO2	۰/۰۰۱۰±۰/۰۷۲۱	۹۲/۵۲۸۶
	CGPSO3	۰/۰۰۰۱±۰/۰۰۱۴	۹۴/۱۲۴۵
	CGPSO4	۰/۰۰۱۱±۰/۰۷۲۸	۹۰/۱۲۴۷
	PSO	۰/۰۴۵۰۸±۰/۰۰۰۶	۸۹/۵۸۷۹
	GWO	۰/۰۰۱۵±۰/۰۱۱۱	۹۲/۱۷۸۹
	BBO	۰/۰۰۱۸±۰/۰۳۹۱	۹۰/۰۰۱۲
غیرفعال	CGPSO1	۰/۰۱۴۰±۰/۰۹۴۲	۸۹/۵۴۷۸
	CGPSO2	۰/۰۰۳۵±۰/۰۰۵۸	۹۵/۵۴۸۷
	CGPSO3	۰۴۰۷/۵۰۶۹±۰/۱۹	۹۶/۹۶۸۷
	CGPSO4	۰/۰۰۱۳±۰/۰۰۱۴	۹۲/۲۱۴۷
	PSO	۰/۰۰۴۱±۰/۰۷۲۸	۹۰/۲۱۹۸
	GWO	۰/۰۰۰۱±۰/۰۴۹۱	۹۳/۴۵۸۷
BBO	۰/۰۰۰۱±۰/۰۴۹۱	۹۴/۹۴۷۸	

ممیز ثابت با ۳۶ بیت شروع می‌شود، با این حال پهنای بیت‌ها با گذر از بلوک‌های مختلف XSG کاهش پیدا می‌کند. در بیشتر بلوک‌ها از فرمت FIX_24_19 استفاده شده است که به معنای پهنای ۲۴ بیت با قسمت اعشاری ۱۹ بیتی است.

تراشه‌های در نظر گرفته شده برای بردهای پردازشی Xilinx Virtex xc7vx550t- و Kintex xc7k325t-2fbg676 با 2ffg1158 در درجه سرعت ۲- هستند. جدول (۶) میزان منابع مصرفی، توان کلی مصرفی و بیشینه فرکانس کاری را که توسط ابزار Xilinx ISE 14.7 پس از اجرا و تأیید طرح ثبت شده است را نمایش می‌دهد.

پیش‌پردازش و استخراج ویژگی با توجه به توضیحات بخش قبل به‌طور مستقیم و به‌صورتی که در ادامه توضیح داده خواهد شد، پیاده‌سازی گردید. این در حالی است که پیاده‌سازی شبکه‌های عصبی تکاملی در دو مرحله انجام شد. بدین‌صورت که در مرحله اول در محیط نرم‌افزار Matlab و به‌صورت ممیز شناور با دقت ۳۲ بیت انجام گردید و پس از ثابت شدن وزن‌ها و بایاس‌ها مقادیر بهینه آن‌ها به فرمت ممیز ثابت با دقت ۱۸ بیت تبدیل شد و برای ساخت شبکه عصبی تکاملی در محیط XSG استفاده گردید.

به‌منظور داشتن نتایج مشابه Matlab کار پردازش با قالب

جدول ۶. میزان منابع و توان کلی مصرفی و همچنین بیشینه فرکانس کاری دسته‌بندی‌کننده پیاده‌سازی شده.

Virtex xc7vx550t-2ffg1158		Kintex xc7k325t-2fbg676		تراشه استفاده شده
موجود در تراشه	استفاده شده	موجود در تراشه	استفاده شده	
۸۶۶۰۰	۸۷۱۴	۵۰۹۵۰	۸۵۴۷	Slices
۶۹۲۸۰۰	۱۵۴۴۵	۴۰۷۶۰۰	۱۵۲۴۸	Flip Flop
۳۴۶۴۰۰	۲۵۰۴۵	۲۰۳۸۰۰	۲۵۴۷۸	LUTs
۳۵۰	۲۰	۴۰۰	۲۰	Bonded IOBs
۲۶۵۰	۶	۸۹۰	۶	RAMB18E1s
۲۸۸۰	۱۶۳	۸۴۰	۱۶۳	DSP48E1s
۳۴ مگاهرتز		۲۷ مگاهرتز		حداکثر فرکانس کاری
۲/۵۶۴ وات		۰/۱۱۱ وات		مجموع توان مصرفی

معماری بر روی تراشه Virtex xc7vx550t-2ffg1158 فرکانس کاری حدوداً ۳۴ مگاهرتز را نتیجه می‌دهد، ولی توان مصرفی آن کمتر از ۲/۵۶۴ وات است. با توجه به این‌که فرکانس نمونه‌برداری قسمت پیش‌پردازش در مسئله دسته‌بندی اهداف سوناری در بدترین حالت ممکن حداکثر ۲ کیلوهرتز است، این معماری طراحی شده برای کاربردهای دسته‌بندی مستقل بلادرنگ بسیار مناسب است. البته باید ذکر کرد که این معماری بر روی تراشه های ارزان قیمت‌تر مانند Artix-7 xc7a100t با ۲۱۹ عدد DSP48E1s نیز قابل پیاده‌سازی است.

۳-۶. محاسبه پیچیدگی

همان‌گونه که در مراجع مختلف اثبات شده است [۴۲ و ۴۳] برای محاسبه حجم پردازش یا همان پیچیدگی محاسباتی روش‌های مختلف، رابطه دقیقی وجود ندارد و فقط می‌توان تخمینی از حجم محاسباتی روش‌ها ارائه نمود. در این قسمت برای تخمین پیچیدگی الگوریتم پیشنهادی و الگوریتم‌های معیار از تابعی به نام $O^1(n)$ که تابع زمانی الگوریتم نامیده می‌شود در نظر گرفته

معماری موردنظر از ۱۶۳ بلوک DSP48E1s استفاده می‌کند. این مورد با معماری موازی شبکه عصبی MLP که نیازمند ۱۳ ضرب کننده برای هر نرون لایه مخفی و ۷ ضرب کننده برای هر نرون لایه خروجی است، توجیه می‌شود. بنابراین، شبکه عصبی MLP به $7 \times 13 + 3 \times 7 = 112$ بیتی نیاز دارد. قسمت طیف توان به دو ضرب کننده ۳۶ بیتی، قسمت پنجره دهی به ۱ ضرب کننده ۳۶ بیتی، زیرسامانه فیلترهای Mel به ۱۳ ضرب کننده ۲۴ بیتی و زیرسامانه Log and DCT به ۱۳ ضرب کننده ۱۸ بیتی نیاز دارند. با در نظر گرفتن این‌که هر رشته DSP48E1 شامل یک ضرب کننده 18×25 است، ضرب دو عدد ۳۶، ۲۴ و ۱۸ بیتی (ممیز ثابت) به‌ترتیب نیازمند ۴، ۲ و ۱ عدد DSP48E1s است. بنابراین، کل طرح به $112 + 13 \times 13 + 1 \times 13 + 1 \times 112 = 163$ DSP48E1s عـــدد نیازمند است. به‌جز تعداد زیاد DSP48E1s این معماری فقط بخش کوچکی از منابع در دسترس این مدل‌های FPGA را مصرف می‌کند که در جدول (۶) نمایش داده شده است.

معماری پیاده شده بر روی تراشه Kintex xc7k325t-2fbg676 فرکانس حدوداً ۲۷ مگاهرتز کار می‌کند و توان مصرفی آن کمتر از ۱۱۱ میلی وات است. این در حالی است که پیاده‌سازی همان

۱. در نظریه پیچیدگی محاسباتی، نماد O بزرگ (Big O notation) برای نشان دادن رابطه میان تعداد داده‌ها و منابع محاسباتی مورد نیاز برای حل یک مسئله با استفاده از یک الگوریتم استفاده می‌شود. استفاده از این نماد معمولاً برای بررسی زمان و یا حافظه مورد نیاز برای حل مسئله‌ای با تعداد زیادی ورودی است.

تعداد شکارچیان، تعداد متغیرها، حداکثر تعداد تکرارها و همچنین فرآیند مرتب کردن در هر تکرار بستگی دارد. از آنجاکه در این الگوریتم‌ها نیز از روش مرتب کردن سریع برای مرتب کردن شکارچیان استفاده شده است، مرتبه پیچیدگی آن در بهترین و بدترین حالت به ترتیب $O(n \log n)$ و $O(n^2)$ است. برای این الگوریتم‌ها پیچیدگی محاسباتی توسط روابط (۱۹) و در نتیجه (۲۰) محاسبه می‌گردد:

$$O(\text{Hunting-Based}) = O(t(O(\text{Quick sort}) + O(\text{position update}))) \quad (19)$$

$$O(\text{Hunting-Based}) = O(t(n^2 + n \times d)) = O(tn^2 + tnd) \quad (20)$$

که در این روابط، n مبین تعداد شکارچیان، t نشان‌دهنده بیشینه تعداد تکرارها و d نشان‌دهنده تعداد متغیرها است.

۳-۳-۶. پیچیدگی محاسباتی دسته‌بندی‌کننده‌های مبتنی بر PSO و CGPSO

با توجه به مطالب شرح داده شده در قسمت‌های قبل و مرجع [۴۳] پیچیدگی محاسباتی الگوریتم‌های مبتنی بر PSO به حداکثر تعداد تکرار و همچنین تعداد جمعیت اولیه بستگی دارد. همان‌گونه که در [۴۳] اثبات شده است، این پیچیدگی در حالت معمولی $O(p \times n \times \log(n))$ و در بدترین حالت $O(p \times n^2)$ است. که در این روابط p حداکثر تعداد تکرار و n تعداد جمعیت اولیه است.

باید به این نکته توجه کرد که در توسعه الگوریتم PSO هیچ‌گونه پیچیدگی محاسباتی جدیدی به الگوریتم اضافه نشده است. بنابراین، پیچیدگی محاسباتی دسته‌بندی‌کننده‌های مبتنی بر این روش توسعه‌یافته با دسته‌بندی‌کننده مبتنی بر الگوریتم PSO کلاسیک، یکسان است.

همان‌گونه که دیده می‌شود؛ الگوریتم CGPSO دارای پیچیدگی کمتر و یا قابل‌مقایسه با روش‌های معیار دیگر است؛ این در حالی است که با پیچیدگی کمتر یا برابر الگوریتم‌های معیار، دقت دسته‌بندی بالاتری را ارائه می‌کند.

۷. نتیجه‌گیری

در این مقاله، طراحی سامانه با قابلیت دسته‌بندی اهداف سوناری فعال و غیرفعال با استفاده از شبکه‌های عصبی پرسپترون چندلایه انجام شده و سعی گردیده که نواقص پرسپترون‌های چندلایه در کار با داده‌های دنیای واقعی، همچنین دقت دسته‌بندی پایین و سرعت همگرایی کم، با استفاده از یک الگوریتم فرا ابتکاری جدید بانام بهینه‌ساز ازدحام ذرات با گروه‌های

خواهد شد که در آن، n اندازه ورودی مسئله است.

باید توجه کرد که پیچیدگی روش پیشنهادی وابسته به تعداد نمونه‌های آموزش در مجموعه داده‌ها، ساختار شبکه عصبی MLP و پیچیدگی الگوریتم‌های فرا ابتکاری آموزش است. بنابراین، پیچیدگی کلی دسته‌بندی‌کننده طراحی‌شده از رابطه (۱۶) محاسبه می‌گردد.

$$O(\text{Classifier}) = O(g(O(\text{MLP}) + O(\text{Training_Algorithm}(m)))) \quad (16)$$

در ادامه پیچیدگی محاسباتی دسته‌بندی‌کننده طراحی‌شده با روش‌های متعارف مقایسه می‌گردد.

۳-۳-۶. پیچیدگی محاسباتی دسته‌بندی‌کننده مبتنی بر الگوریتم BBO

علاوه بر موارد ذکرشده در بالا، پیچیدگی الگوریتم BBO وابسته به تعداد زیستگاه‌ها، تعداد نسل‌ها، فرآیند جهش و نخبه‌گزینی است. بنابراین، پیچیدگی محاسباتی کلی دسته‌بندی‌کننده‌های مبتنی بر BBO طبق رابطه (۱۷) محاسبه می‌شود:

$$O(\text{MLP}, \text{BBO}) = O(g(O(\text{MLP}) + O(\text{migration}) + O(\text{mutation}) + O(\text{elitism}))) \quad (17)$$

که در این رابطه، g نشان‌دهنده حداکثر تعداد نسل‌ها است. پیچیدگی محاسباتی یک MLP با h نرون لایه مخفی، o نرون خروجی و t نمونه آموزش توسط $O(t(h+o))$ محاسبه می‌شود. پیچیدگی محاسباتی مهاجرت $O(mn^2)$ است که در آن m تعداد ساکنین و n مبین تعداد زیستگاه است. البته پیچیدگی بهترین حالت ممکن مهاجرت $O(mn)$ خواهد بود. پیچیدگی محاسباتی عملگر جهش در بدترین حالت $O(mn)$ است. از آنجاکه در فاز نخبه‌گزینی از روش مرتب کردن سریع برای مرتب کردن بهترین زیستگاه‌ها استفاده می‌شود، پیچیدگی محاسباتی عملگر نخبه‌گزینی از درجه $O(n \log n)$ در بهترین حالت و $O(n^2)$ در بدترین حالت است. بنابراین، پیچیدگی محاسباتی کلی دسته‌بندی‌کننده مبتنی بر BBO طبق رابطه (۱۸) محاسبه می‌شود:

$$O(\text{MLP}, \text{BBO}) = O(g(t(h+o) + mn^2 + nm + n^2)) \quad (18)$$

که در این رابطه، g مبین بیشینه تعداد نسل‌ها، t نشان‌دهنده تعداد نمونه‌های آموزش، h و o به ترتیب مبین تعداد نرون لایه مخفی و خروجی، m مبین تعداد ساکنین و n نشان‌دهنده تعداد زیستگاه‌ها است.

۳-۳-۶. پیچیدگی محاسباتی دسته‌بندی‌کننده مبتنی بر الگوریتم GWO

پیچیدگی محاسباتی الگوریتم‌های مبتنی بر الگوریتم GWO به

- and Extended Kalman Filter”; IEEE Conf. Guidance, Nav. Control 2014, 2258- 2263.
- [12] Simon, D. “Training Radial Basis Neural Networks with the Extended Kalman Filter”; Neurocomputing 2002, 48, 455-475.
- [13] Zhang, Q.; Li, B. “A Low-Cost GPS/INS Integration Based on UKF and BP Neural Network”; IEEE Conf. Intel. Control and Inf. Proc. 2014, 100-107.
- [14] Mosavi, M. R.; Khishe, M.; Akbarisani, M. “Neural Network Trained by Biogeography-based Optimizer with Chaos for Sonar Data Set Classification”; Wireless Person. Comput. 2017, 95, 1-20.
- [15] Li, X.; Zhang, T.; Deng, Z.; Wang, J. “A Recognition Method of Plate Shape Defect Based on RBF-BP Neural Network Optimized by Genetic Algorithm”; IEEE Conf. on Control and Decision 2014, 3992-3996.
- [16] Kirkpatrick, S.; Gelatt, C. D.; Vecchi, M. P. “Optimization by Simulated Annealing”; Science, New Series, 1983, 220, 671-680.
- [17] Ozturk, C.; Karaboga, D. “Hybrid Artificial Bee Colony Algorithm for Neural Network Training”; IEEE Congress Evol. Comput. 2011, 84-88.
- [18] Yu, J. J.; Lam, A. Y.; Li, V. O. “Evolutionary Artificial Neural Network based on Chemical Reaction Optimization”; IEEE Congress Evol. Comput. 2011, 2083-2090.
- [19] Mirjalili, S.; Sadiq, A. S. “Magnetic Optimization Algorithm for Training Multi-Layer Perceptron”; IEEE Conf. Comm. Soft. Networks 2011, 42-46.
- [20] Green, R. C.; Wang, L.; Alam, M. “Training Neural Networks Using Central Force Optimization and Particle Swarm Optimization: Insights and Comparisons”; Expert Sys. App. 2012, 39, 555-563.
- [21] Moallem, P.; Razmjoo, N. “A Multi-Layer Perceptron Neural Network Trained by Invasive Weed Optimization for Potato Color Image Segmentation”; Trend. Appl. Sci. Res. 2012, 7, 445-455.
- [22] Pereira, L. A.; Afonso, L. C.; Papa, J. P.; Vale, Z. A.; Ramos, C. C.; Gastaldello, D. S.; Souza, A. N. “Multilayer Perceptron Neural Networks Training Through Charged System Search and Its Application for Non-Technical Losses Detection on Innovative Smart Grid Technologies”; IEEE PES Conf. Latin America 2013, 1-6, 2013.
- [23] Pereira, L.; Rodrigues, D.; Ribeiro, P.; Papa, J.; Weber, S. A. “Social-Spider Optimization-Based Artificial Neural Networks Training and its Applications for Parkinson’s Disease Identification”; IEEE Symp. Comput. Sys. 2014, 14-17.
- [24] Uzlu, E.; Kankal, M.; Akpınar, A.; Dede, T. “Estimates of Energy Consumption in Turkey using Neural Networks with the Teaching-Learning-based Optimization Algorithm”; Energy 2014, 75, 295-303.
- [25] Mosavi, M. R.; Khishe, M.; Ghamgosar, A. “Classification of Sonar Data Set using Neural Network Trained by Gray Wolf Optimization”; J. Neural Network World 2016, 26, 393-415.
- [26] Mosavi, M. R.; Khishe, M.; “Training a Feed-Forward Neural Network using Particle Swarm Optimizer with Autonomous Groups for Sonar Target Classification”; J. Circuits, Sys. Comput. 2017, 26, 1-20.
- [27] Ravakhah, S.; Khishe, M.; Aghababae, M.; Hashemzadeh, E. “Sonar False Alarm Rate Suppression using Classification Methods Based on Interior Search Algorithm”; Int. J. Comput. Sci. Network Security 2017, 17.

آشفته (CGPSO) حل شود. همان‌گونه که نشان داده شد، این الگوریتم با استفاده از گروه‌های مجزای جستجو و همچنین نقشه‌های آشفته، فضای جستجو را بهتر و سریع‌تر اکتشاف می‌کند. به‌منظور ارزیابی سامانه طراحی‌شده، یک مجموعه داده سوناری مرجع، یک مجموعه داده آزمایشگاهی غیرفعال و یک مجموعه داده واقعی فعال استفاده شد. در ادامه، سامانه طراحی‌شده با بهینه‌سازهای معیار ازدحام ذرات (PSO)، جغرافیایی زیستی (BBO) و گرگ خاکستری (GWO) از نظر سرعت همگرایی، دقت دسته‌بندی و قابلیت اعتماد مقایسه شد. نتایج نشان داد که سامانه طراحی‌شده نسبت به بهترین دسته‌بندی‌کننده موجود، به‌طور میانگین ۲/۳۳ درصد دقیق‌تر عمل می‌کند.

۸. مراجع‌ها

- [1] Mosavi, M. R.; Khishe, M.; Ebrahimi, E. “Classification of Sonar Targets using OMKC, Genetic Algorithm and Statistical Moments”; J. Adv. Comput. Res. 2016, 7, 143-156.
- [2] Fialkowski, J. M.; Gauss, R. C. “Methods for Identifying and Controlling Sonar Clutter”; IEEE J. Ocean Eng. 2010, 35, 330-354.
- [3] Mosavi, M. R.; Khishe, M.; Aghababae, M.; Mohammadzadeh, F. “Approximation of Active Sonar Clutter’s Statistical Parameters Using Array’s Effective Beam-Width”; Iranian J. Marine Sci. Technol. 2015, 73, 11-22.
- [4] Khishe, M.; Aghababae, M. “Identifying and Controlling Sonar Clutter by Clutter Indelible Method”; Iranian Conf. Elec. Comput. Eng. 2013, 523-529.
- [5] Mosavi, M. R.; Khishe, M.; Hatam Khani, Y.; Shabani, M. “Training Radial Basis Function Neural Network using Stochastic Fractal Search Algorithm to Classify Sonar Dataset”; Iranian J. Elec. Eng. 2017, 13, 100-112.
- [6] Mosavi, M. R.; Kaveh, M.; Khishe, M. “Sonar Data Set Classification using MLP Neural Network Trained by Non-linear Migration Rates BBO”; Fourth Iranian Conf. Eng. Electro. 2016, 1-5.
- [7] Mosavi, M. R.; Kaveh, M.; Khishe, M.; Aghababae, M. “Design and implementation a Sonar Data Set Classifier by using MLP NN Trained by Improved Biogeography-based Optimization”; Second National Conf. Marine Technol. MMT2016.
- [8] Auer, P.; Burgsteiner, H.; Maass, W. “A Learning Rule for Very Simple Universal Approximators Consisting of a Single Layer of Perceptrons”; Neural Networks 2008, 21, 786-795.
- [9] Moody, J.; Darken, C. J. “Fast Learning in Networks of Locally-Tuned Processing Units”; Neural Comput. 1989, 1281-294.
- [10] Karayiannis, N. “Reformulated Radial Basis Neural Networks Trained by Gradient Descent”; IEEE Trans. Neural Networks 1999, 10, 657-671.
- [11] Liu, C.; Wang, H.; Yao, P. “On Terrain-Aided Navigation for Unmanned Aerial Vehicle using B-spline Neural Network

- [35] Khishe, M.; Mosavi, M. R.; Moridi, A. "Chaotic Fractal Walk Trainer for Sonar Data Set Classification using Multi-Layer Perceptron Neural Network and its Hardware Implementation"; *Appl. Acoustics* 2018, 137, 121-139.
- [36] <http://archive.ics.uci.edu/ml/datasets>.
- [37] Gorman R. P.; Sejnowski, T. J. "Analysis of Hidden Units in a Layered Network Trained to Classify Sonar Targets"; *Neural Networks*, 1988, 1, 75-89.
- [38] Khishe, M.; "Passive Sonar Data Set"; Mendeley Data, v1, 2017. <http://dx.doi.org/10.17632/2m2pnnrd8b.1>
- [39] Khishe, M.; Mosavi, M. R. "Active Sonar Data Set"; Mendeley Data, v1, 2017. <http://dx.doi.org/10.17632/fyxjwzphf.1>
- [40] Gaggero, S.; Savio, L.; Brizzolara, S.; Viviani, M.; Ferrando, M.; Conti, F. "An Experimental Study on Measuring and Localizing Propeller Noise behind a Body in a Cavitation Tunnel"; *First Int. Symp. Marine Propulsors*, Trondheim, 2009.
- [41] Carlton, J. "Marine Propeller and Propulsion"; Section 10, Butterworth-Heinemann, 3rd Edition, 2012.
- [42] Gacs, P.; Lovasz, L. "Complexity of Algorithms"; *Lecture Notes*, Boston University, 1999, 185-198.
- [43] Iyer, K. "Computational Complexity of Data Mining Algorithms used in Fraud Detection"; M.Sc. Thesis, Pennsylvania State University, 2015.
- [28] سید محمدرضا موسوی، محمد خویشه، فلاح محمدزاده، هومان علانیان، "دسته‌بندی اهداف سوناری با استفاده از شبکه‌های عصبی مصنوعی آموزش دیده مبتنی بر جغرافیای زیستی" علوم و فناوری‌های پدافند نوین، سال هفتم، شماره ۲، تابستان ۱۳۹۶
- [29] Kaveh, M.; Khishe, M.; Mosavi, M. R. "Design and Implementation of a Neighborhood Search BBO Trainer for Classifying Sonar Data Set using Multi-Layer Perceptron Neural Network"; *Analog Int. Circuits Signal Proc.* 2018.
- [30] Khishe, M.; Safari, A. "Classification of Sonar Targets using an MLP Neural Network Trained by Dragonfly Algorithm"; *Wireless Person. Sys.* 2019, 108, 2241-2260.
- [31] Afrakhteh, S.; Mosavi, M. R.; Khishe, M.; Ayatollahi A. "Accurate Classification of EEG Signals using Neural Networks Trained by Hybrid Population-Physic-Based Algorithm"; *Int. J. Auto. Comput.* 2018, 1-15.
- [32] Mosavi, M. R.; Khishe, M.; Parvizi, G. R.; Naseri, M. J.; Ayat, M. "Training Multi-Layer Perceptron Utilizing Adaptive Best-mass Gravitational Search Algorithm to Classify Sonar Dataset"; *Archive Acoust.* 2019, 44, 137-151.
- [33] Khishe, M.; Mohammadi, H. "Sonar Target Classification using Multi-Layer Perceptron Trained by Salp Swarm Algorithm"; *Ocean Eng.* 2019, 181, 98-108.
- [34] Wolpert, D. H.; Macready, W. G. "No Free Lunch Theorems for Optimization"; *IEEE Trans. Evol. Comput.* 1997, 1, 67-82.