

دسته بندی دادگان سونار با استفاده از الگوریتم بهینه ساز گرگ خاکستری

سید محمد رضا موسوی^۱، محمد خویشه^۲، ابوالفضل غمگسار^۳، محمد جواد قلندری^۴

۱ استاد، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران m_mosavi@iust.ac.ir

۲ دانشجوی دکتری الکترونیک، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران

۳ دانشجوی کارشناسی ارشد الکترونیک، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران

۴ کارشناس ارشد الکترونیک، دانشکده مهندسی برق، دانشگاه علوم دریایی امام خمینی

تاریخ دریافت: ۹۳/۸/۲۰ تاریخ پذیرش: ۹۴/۹/۱۸

چکیده

این مقاله از یک روش فرا ابتکاری جدید به نام بهینه ساز گرگ خاکستری (GWO) به منظور دسته بندی دادگان سونار استفاده می کند. الگوریتم GWO از سلسله مراتب رهبری و سازوکار شکار گرگ های خاکستری در طبیعت تقلید می کند. در این الگوریتم از چهار نوع گرگ خاکستری شامل آلفا، بتا، دلتا و امگا برای شبیه سازی سلسله مراتب رهبری استفاده شده است. علاوه بر این، سه مرحله اصلی شکار شامل جستجوی طعمه، محاصره طعمه و حمله به طعمه شبیه سازی می شوند. در ابتدا الگوریتم مورد نظر توسط ۲۳ تابع آزمون شناخته شده به خوبی ارزیابی شده و نتایج به دست آمده با روش بهینه سازی ازدحام ذرات (PSO) مقایسه می شوند. نتایج نشان می دهد که الگوریتم GWO قادر به ارائه نتایجی بسیار بهتر در یافتن کمینه کلی توابع، سرعت همگرایی و اجتناب از کمینه محلی در مقایسه با الگوریتم PSO است. علاوه بر این، در این مقاله یک کاربرد واقعی از روش ارائه شده در زمینه دسته بندی دادگان سونار بیان می شود. نتایج حاصله نشان می دهد که دسته بندی کننده طراحی شده با الگوریتم گرگ خاکستری دادگان سونار را با دقت ۹۶/۶۷٪ دسته بندی می کند، این در حالی است که PSO دقت ۹۲/۳۳٪ را حاصل می نماید.

کلیدواژه

بهینه ساز گرگ خاکستری، بهینه ساز ازدحام ذرات، دسته بندی، سونار.

مقدمه

این سؤال را می توان به چهار دلیل اصلی سادگی، انعطاف پذیری، ساز و کار آزاد از مشتق^۵ و اجتناب از گیر افتادن در بهینه محلی^۶ خلاصه کرد.

روش های فرا ابتکاری نسبتاً ساده هستند. آن ها عمدتاً از مفاهیم بسیار ساده الهام گرفته شده اند. الهام ها به طور معمول از پدیده های فیزیکی، رفتارهای حیوانات و یا مفاهیم تکاملی گرفته می شوند. این سادگی به دانشمندان کامپیوتر اجازه می دهد تا مفاهیم طبیعی مختلف را شبیه سازی کرده و روش های فرا اکتشافی جدیدی پیشنهاد کنند. همچنین می توانند دو یا چند روش فرا اکتشافی را باهم ترکیب کرده و یا روش های موجود را بهبود بخشند. علاوه بر این سادگی عنوان شده، به دانشمندان دیگر این اجازه را می دهد این روش ها را به سرعت فرا گرفته و آن ها را به مسائل خود اعمال کنند.

روش های بهینه سازی فرا ابتکاری^۱ در طول دو دهه گذشته بسیار محبوب شده و مورد توجه قرار گرفته اند. باکمال تعجب برخی از روش ها مانند الگوریتم ژنتیک^۲ (GA) [۱]، الگوریتم کلونی مورچگان^۳ (ACO) [۲] و بهینه سازی ازدحام ذرات^۴ (PSO) [۳]، نه تنها در میان دانشمندان علوم کامپیوتر بلکه دانشمندان فعال در سایر زمینه ها نسبتاً شناخته شده هستند. با توجه به تعداد زیاد کارهای نظری، از این تکنیک های بهینه سازی در زمینه های مختلف مطالعه استفاده شده است. سؤالی که ممکن است مطرح شود این است که چرا روش های فرا اکتشافی به صورت قابل ملاحظه ای رایج شده اند. پاسخ به

5 Derivation-Free Mechanism
6 Local Optima Avoidance

1 Meta-Heuristic
2 Genetic Algorithm
3 Ant Colony Optimization
4 Particle Swarm Optimization

مقابل در دسته چند راه‌حلی، بهینه‌سازی با استفاده از مجموعه‌ای از راه‌حل‌ها (جمعیت^{۱۳}) انجام می‌گیرد. در این مورد، فرآیند جستجو با جمعیت اولیه تصادفی (راه‌حل‌های متعدد) شروع می‌شود و این جمعیت در طول تکرار بهبود می‌یابد. روش‌های فرا ابتکاری چند راه‌حلی نسبت به الگوریتم‌های تک راه‌حلی چندین مزایا دارند که عبارتند از:

- راه‌حل‌های چندگانه اطلاعات مربوط به فضای جستجو را به اشتراک می‌گذارند که باعث جهش‌های ناگهانی به سمت بخش امیدوارکننده و مطلوب از فضای جستجو می‌شود.
- راه‌حل‌های چندگانه باعث جلوگیری از ایجاد راه‌حل‌های بهینه محلی می‌گردند.
- روش‌های فرا ابتکاری چند راه‌حلی نسبت به الگوریتم‌های تک راه‌حلی قابلیت کشف و شناسایی بیشتری دارند.

یکی از شاخه‌های جالب از روش‌های فرا ابتکاری چند راه‌حلی، هوش ازدحامی یا هوش گروهی^{۱۴} (SI) است. مفاهیم اولیه SI، اولین بار در سال ۱۹۹۳ پیشنهاد شد [۶]. با توجه به بررسی‌های بونابو^{۱۵} و همکارانش [۱]، SI برای هوش جمعی گروهی از عوامل ساده است. این الهام بخشی بیشتر از کلونی‌های طبیعی، گله‌ها، گروه‌ها و دسته‌ها سرچشمه می‌گیرد. برخی از محبوب‌ترین تکنیک‌های SI، شامل ACO [۲]، PSO [۳] و کلونی زنبور عسل مصنوعی^{۱۶} (ABC) [۷] است. یک بررسی جامع از الگوریتم‌های SI در بخش بعدی ارائه می‌شود. برخی از مزایای استفاده از الگوریتم‌های SI به شرح زیر است:

- الگوریتم‌های SI، اطلاعات مربوط به فضای جستجو را در طول یک دوره تکرار^{۱۷}، حفظ می‌کنند. این در حالی است که الگوریتم‌های تکاملی^{۱۸} (EA) اطلاعات مربوط به نسل‌های قبلی را دور می‌اندازند.
- الگوریتم‌های SI اغلب از حافظه برای ذخیره بهترین راه‌حل به دست آمده استفاده می‌کنند.
- الگوریتم‌های SI معمولاً پارامترهای کمتری برای تنظیم دارند.
- الگوریتم‌های SI در مقایسه با روش‌های تکاملی عملگرهای کمتر دارند (تولیدمثل، جهش و غیره).
- پیاده‌سازی الگوریتم‌های SI آسان است.

انعطاف‌پذیری روش‌های فرا ابتکاری نشان‌دهنده استفاده از این روش‌ها در مسائل مختلف بدون ایجاد هیچ‌گونه تغییر خاصی در ساختار الگوریتم است. از آنجایی که در روش‌های فرا ابتکاری مسائل به‌عنوان جعبه‌های سیاه^{۱۹} در نظر گرفته می‌شوند، به‌راحتی به مسائل مختلف اعمال می‌گردند. به‌عبارت‌دیگر تنها ورودی‌ها و خروجی‌های یک سیستم برای یک روش فرا اکتشافی مهم هستند؛ بنابراین تنها موضوع مهم برای طراح این است که چگونه مسئله خود را به روش اعمال کند.

اکثر روش‌های فرا ابتکاری ساز و کار آزاد از مشتق دارند. روش‌های فرا ابتکاری در مقایسه با روش‌های بهینه‌سازی مبتنی بر گرادیان^{۲۰}، مسائل را به‌صورت تصادفی بهینه‌سازی می‌کنند. فرآیند بهینه‌سازی با استفاده از راه‌حل‌های تصادفی شروع می‌شود و نیازی به محاسبه مشتق فضاهای جستجو برای پیدا کردن مقدار بهینه وجود ندارد. این باعث می‌شود روش‌های فرا ابتکاری برای مسائل حقیقی با مشتقات سنگین و ناشناخته بسیار مناسب باشد.


روش‌های فرا ابتکاری برای جلوگیری از گیرکردن در بهینه‌های محلی در مقایسه با تکنیک‌های بهینه‌سازی معمولی دارای توانایی‌های برتری هستند. این به دلیل ماهیت تصادفی روش‌های فرا ابتکاری است که از گیرکردن در بهینه‌های محلی و جستجوی گسترده در کل فضای جستجو جلوگیری می‌کند. در اینجا به قضیه «نظریه بدون ناهار رایگان»^{۲۱} [۴] یا به‌اختصار NFL اشاره می‌کنیم. این قضیه به‌صورت منطقی ثابت می‌کند هیچ روش فرا ابتکاری وجود ندارد که برای حل تمام مسائل بهینه‌سازی مناسب باشد. به‌عبارت‌دیگر یک روش فرا ابتکاری خاص ممکن است بر روی یک مجموعه از مسائل نتایجی امیدوارکننده، اما همان الگوریتم بر روی یک مجموعه دیگر عملکردی ضعیف داشته باشد. بدیهی است NFL باعث می‌شود این زمینه مطالعاتی بسیار فعال شده و منجر به ارتقاء روش‌های فعلی و پیشنهاد روش‌های فرا ابتکاری جدید در هر سال گردد. همچنین این قضیه باعث افزایش تلاش‌ها برای توسعه یک روش فرا ابتکاری جدید الهام گرفته از گرگ‌های خاکستری می‌شود.

به‌طور کلی روش‌های فرا ابتکاری را می‌توان به دو دسته اصلی تک راه‌حلی^{۲۲} و چند راه‌حلی^{۲۳} تقسیم کرد. در دسته تک راه‌حلی (به‌عنوان مثال الگوریتم تبرید تدریجی^{۲۴} [۵])، فرآیند جستجو با یک راه‌حل کاندید شروع می‌شود، سپس این راه‌حل کاندیدای واحد در طول تکرارهای بعدی بهبود می‌یابد. در

13 Population
14 Swarm Intelligence
15 Bonabeau
16 Artificial Bee Colony
17 Course of Iteration
18 Evolutionary Algorithms

7 Black Boxes
8 Gradient-Based
9 No Free Lunch
10 Single-Solution-Based
11 Population-Based
12 Simulated Annealing

به سمت پایین به رسمیت می‌شناسد. با توجه به این که دستورات آلفا باید توسط گروه پیروی شود، گرگ آلفا را گرگ غالب نیز می‌نامند [۱۳ و ۹]. گرگ‌های آلفا تنها مجاز به انتخاب همسر در گروه هستند. جالب توجه این است که آلفا لزوماً قوی‌ترین عضو گروه نیست، اما بهترین عضو از نظر مدیریت گروه است. این نشان می‌دهد که سازمان و نظم یک گروه از قدرت آن بسیار مهم‌تر است.



شکل ۱. سلسله مراتب گرگ خاکستری (سلطه از بالا به پایین کاهش می‌یابد)

سطح دوم در سلسله مراتب گرگ‌های خاکستری، بتا است. گرگ‌های بتا، گرگ‌های زیردست هستند که به آلفا در تصمیم‌گیری‌ها یا فعالیت‌های دیگر گروه کمک می‌کنند. گرگ بتا می‌تواند نر یا ماده باشد و در صورتی که آلفا خیلی پیر شود یا بمیرد، احتمالاً بهترین نامزد برای جایگزینی آلفا است. گرگ بتا باید به آلفا احترام بگذارد و در عین حال به گرگ‌های سطح پایین‌تر نیز فرمان دهد. در حقیقت بتا نقش مشاور آلفا و سازمان دهنده گروه را بازی می‌کند. بتا دستورات آلفا را در سراسر گروه اجرا کرده و بازخورد آن را به آلفا ارجاع می‌دهد. پایین‌ترین رتبه را در گرگ‌های خاکستری، امگا دارد. امگا نقش قربانی را بازی می‌کند. گرگ امگا همیشه باید مطیع دیگر گرگ‌های غالب باشد. آن‌ها آخرین گروه از گرگ‌هایی هستند که مجاز به خوردن هستند. به نظر می‌رسد امگا نقش مهمی را در گروه بازی نمی‌کند، اما مشاهده شده است که کل گروه با از دست دادن امگا با جنگ داخلی و مشکلاتی روبرو شده است. این به دلیل تخلیه خشونت و ناکامی دیگر گرگ‌های گروه توسط امگا است که به حفظ ساختار تسلط و رضایت تمام گروه کمک می‌کند. اگر گرگی آلفا، بتا و یا گاما نباشد، زیردست (و یا دلتا در برخی منابع) نامیده می‌شود. گرگ دلتا باید به آلفا و بتا گزارش دهد، اما آن‌ها بر امگا تسلط دارند. پیشاهنگان، نگهبانان، ارشدان^{۲۳}، شکارچیان و مراقبان، به این دسته تعلق دارند. پیشاهنگان مسئول مراقبت از مرزهای قلمرو و هشدار به گروه در صورت بروز هرگونه خطر هستند. نگهبانان وظیفه حفظ و تضمین امنیت گروه را به عهده دارند. ارشدان، گرگ‌های باتجربه‌ای هستند که قبلاً عنوان آلفا یا بتا را

صرف‌نظر از تفاوت‌های بین روش‌های فرا ابتکاری مختلف، یک ویژگی مشترک بین آن‌ها تقسیم فرآیند جستجو به دو مرحله شناسایی^{۱۹} و بهره‌برداری^{۲۰} [۸-۱۲] است. مرحله شناسایی اشاره به روند بررسی گسترده بخش‌های مطلوب و امیدوارکننده حاصل از فضای جستجو دارد. یک الگوریتم برای این که بتواند به صورت تصادفی و سرتاسری، فضای جستجو را جستجو و مرحله شناسایی را پشتیبانی کند، نیاز به عملگرهایی تصادفی دارد. این در حالی است که مرحله بهره‌برداری اشاره به قابلیت جستجوی محلی در سراسر مناطق مطلوبی دارد که از مرحله شناسایی به دست آمده است. پیدا کردن یک موازنه مناسب بین این دو مرحله با توجه به ماهیت تصادفی روش‌های فرا ابتکاری مسئله‌ای چالش برانگیز است. این مقاله به منظور بهینه‌سازی توابع و دسته بندی دادگان از یک روش SI جدید با الهام از سلسله مراتب اجتماعی و رفتار شکار گرگ‌های خاکستری، استفاده می‌کند. بقیه مقاله به شرح زیر است. بخش دوم الگوریتم پیشنهادی GWO را به طور خلاصه بیان می‌کند. نتایج و توضیحات مربوط به توابع آزمون^{۲۱} و دسته بندی دادگان سونار، در بخش سوم ارائه می‌شود. در نهایت به نتیجه‌گیری و ارائه پیشنهادهایی برای مطالعات آینده می‌پردازیم.

بهینه‌ساز گرگ خاکستری^{۲۲} (GWO)

در این بخش ابتدا منبع الهام روش ارائه شده مورد بحث قرار گرفته و سپس مدل ریاضی آن ارائه می‌شود [۹].

منبع الهام

گرگ خاکستری به خانواده سگ‌سانان تعلق دارد. گرگ‌های خاکستری در رأس شکارچیان قرار دارند؛ بدین معنی که آن‌ها در بالای زنجیره غذایی هستند. گرگ‌های خاکستری بیشتر ترجیح می‌دهند به صورت گروهی زندگی کنند. اندازه گروه به طور متوسط بین ۵ تا ۱۲ نفر است [۹]. آن‌ها یک سلسله مراتب بسیار سخت غالب اجتماعی دارند که در شکل ۱ نشان داده شده است.

رهبران گروه یک جنس نر و یک ماده هستند که آلفا نامیده می‌شوند. آلفا عمدتاً مسئول تصمیم‌گیری در مورد شکار، محل خواب، زمان بیداری و غیره هستند. تصمیمات آلفا به گروه دیکته شده است؛ باین حال نوعی رفتار دموکراتیک نیز مشاهده شده است که در آن یک آلفا از دیگر گرگ‌های گروه پیروی می‌کند. در تجمع گروهی، کل گروه آلفا را با نگاه داشتن دم خود

- 19 Exploration
- 20 Exploitation
- 21 Benchmark Functions
- 22 Gray Wolf Optimizer

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (3)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (4)$$

در معادلات ۳ و ۴، \vec{a} در طول تکرار به صورت خطی از ۲ تا ۰ کاهش می‌یابد. \vec{r}_1 و \vec{r}_2 مبین بردارهای تصادفی در بازه [۰, ۱] هستند.

برای دیدن نتایج معادلات، معادلات ۱ و ۲ به همراه یک بردار مکان دوبعدی و تعدادی همسایگی احتمالی در شکل ۳-الف نشان داده شده‌اند. همان‌طور که در شکل مشاهده می‌شود یک گرگ خاکستری که در مکان (X,Y) قرار دارد، می‌تواند موقعیت خود را با توجه به موقعیت طعمه (X^*, Y^*) عوض کند. مکان‌های مختلف موجود در اطراف بهترین عامل را می‌توان با توجه به موقعیت فعلی آن و تنظیم و تغییر مقدار بردارهای \vec{A} و \vec{C} به دست آورد. به‌عنوان مثال مکان (X^*, Y^*) را می‌توان با مقاردهی به صورت $\vec{A} = (1,0)$ و $\vec{C} = (1,1)$ محاسبه نمود. مکان‌های احتمالی به‌روزشده مربوط به یک گرگ خاکستری در فضای سه‌بعدی در شکل ۳-ب نشان داده شده است. باید توجه داشت که بردارهای تصادفی r_1 و r_2 به گرگ‌ها اجازه دستیابی به هر موقعیتی مابین نقاط نشان داده‌شده در شکل ۳ را می‌دهند. بنابراین یک گرگ خاکستری می‌تواند موقعیت خود را در داخل فضایی که طعمه را در بر گرفته، به صورت تصادفی و با استفاده از معادلات ۵ و ۶ تغییر دهد.

همین مفهوم را می‌توان به یک فضای جستجوی n بعدی تعمیم داد. در این حالت گرگ‌های خاکستری پیرامون بهترین راه‌حل به دست آمده در ابعادی بیشتر از ابعاد مکعب حرکت می‌کنند.

شکار

گرگ خاکستری این توانایی را دارد که محل طعمه را تشخیص داده و آن را محاصره کند. روند شکار معمولاً توسط آلفا هدایت می‌شود. گرگ‌های بتا و دلتا نیز گاهی اوقات ممکن است در شکار شرکت کنند. متأسفانه در یک فضای جستجو انتزاعی هیچ ایده‌ای در مورد موقعیت بهینه (طعمه) وجود ندارد. به‌منظور شبیه‌سازی ریاضی رفتار شکار گرگ‌های خاکستری، فرض می‌کنیم آلفا (بهترین راه‌حل موجود)، بتا و دلتا در مورد مکان بالقوه طعمه آگاهی بهتری دارند. بنابراین سه تا از بهترین راه‌حل‌های به دست آمده را ذخیره کرده و دیگر عوامل جستجو (از جمله گرگ‌های امگا) را وادار می‌کنیم تا موقعیت خود را با توجه به موقعیت بهترین عوامل جستجو به‌روزرسانی نمایند. روابط ۵، ۶ و ۷ در این رابطه ارائه شده است

داشته‌اند. شکارچیان در هنگام شکار طعمه و تأمین مواد غذایی برای گروه به آلفا و بتا کمک می‌کنند. در نهایت، مراقبان مسئولیت مراقبت از گرگ‌های ضعیف، بیمار و زخمی را به عهده دارند. علاوه بر سلسله‌مراتب اجتماعی گرگ‌ها، شکار گروهی یکی دیگر از رفتار اجتماعی جالب گرگ‌های خاکستری است. با توجه به بررسی‌های مورو^{۲۴} و همکارانش [۱۴]، مراحل اصلی شکار گرگ‌های خاکستری به شرح زیر است:

- ردیابی، تعقیب و نزدیک شدن به طعمه.
- تعقیب، محاصره و آزار طعمه تا زمانی که از حرکت بازایستد.
- حمله به سمت طعمه.

این مراحل در شکل ۲ نشان داده شده‌اند.

در این مقاله، این روش شکار و سلسله‌مراتب اجتماعی گرگ‌های خاکستری به‌منظور طراحی GWO و انجام بهینه‌سازی، به صورت ریاضی مدل شده است.

مدل ریاضی و الگوریتم

در این بخش مدل‌های ریاضی مربوط به سلسله‌مراتب اجتماعی، ردیابی، محاصره و حمله به طعمه ارائه شده است. سپس الگوریتم GWO مربوطه مشخص می‌شود [۹].

سلسله‌مراتب اجتماعی

در هنگام طراحی GWO، به‌منظور مدل کردن ریاضی سلسله‌مراتب اجتماعی گرگ‌ها مناسب‌ترین راه‌حل را به‌عنوان آلفا (α) در نظر می‌گیریم. در نتیجه از بین بهترین راه‌حل‌ها، دومین و سومین آن‌ها را بتا (β) و دلتا (δ) نام‌گذاری می‌کنیم. مابقی راه‌حل‌های کاندید شده امگا (ω) در نظر گرفته می‌شوند. در الگوریتم GWO، فرآیند شکار (بهینه‌سازی) توسط α ، β و δ هدایت می‌گردد. گرگ‌های ω از این سه گروه پیروی می‌کنند.

محاصره طعمه

همان‌طور که در بالا ذکر شد، گرگ‌های خاکستری طعمه را در طول شکار محاصره می‌کنند. به‌منظور مدل کردن این رفتار محاصره به صورت ریاضی، معادلات ۱ و ۲ ارائه شده است [۱۳]:

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (1)$$

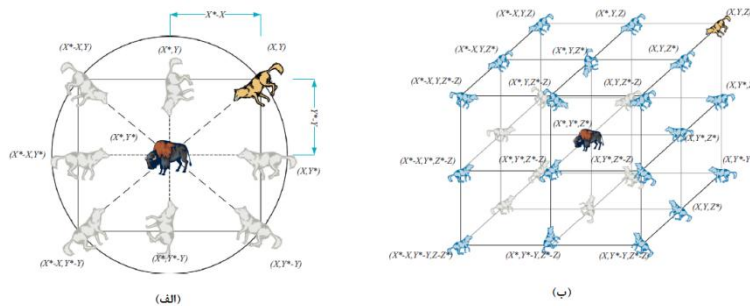
$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (2)$$

در معادلات ۱ و ۲، t مبین تعداد تکرار فعلی است. \vec{A} و \vec{C} مبین بردارهای ضریب، \vec{X}_p مبین بردار موقعیت شکار و \vec{X} مبین بردار موقعیت یک گرگ خاکستری است. بردارهای \vec{A} و \vec{C} به صورت زیر محاسبه می‌شوند:

$$\bar{D}_\alpha = |\bar{C}_1 \bar{X}_\alpha - \bar{X}|, \bar{D}_\beta = |\bar{C}_2 \bar{X}_\beta - \bar{X}|, \bar{D}_\delta = |\bar{C}_3 \bar{X}_\delta - \bar{X}| \quad (5)$$




شکل ۲. رفتار شکار گرگ های خاکستری: (الف) تعقیب، نزدیک شدن و ردیابی طعمه، (ب)، (ج)، (د) تعقیب، محاصره و آزار طعمه و (ه) وضعیت ثابت و حمله [۱۴].



شکل ۳. بردارهای مکان دوبعدی و سه بعدی و موقعیت احتمالی بعدی آنها [۱۳].

در بازه $[-2a, 2a]$ است؛ درحالی که a در طول تکرارها از مقدار ۲ تا ۰ کاهش می‌یابد. زمانی که مقادیر تصادفی \bar{A} در بازه $[-1, 1]$ قرار دارند، موقعیت بعدی یک عامل جستجو می‌تواند در هر موقعیتی مابین موقعیت فعلی آن و موقعیت طعمه باشد. شکل ۴ نشان می‌دهد، مقدار $|A| < 1$ گرگ‌ها را مجبور به حمله به سمت طعمه می‌کند.



شکل ۴. به روز رسانی موقعیت در الگوریتم GWO

با توجه به عملگرهایی که تاکنون ارائه شد، الگوریتم GWO به عوامل جستجوی خود اجازه می‌دهد موقعیت خود را بر اساس موقعیت آلفا، بتا و دلتا به‌روزرسانی کرده و به طعمه حمله کند.

$$\bar{X}_1 = \bar{X}_\alpha - \bar{A}_1 \cdot (\bar{D}_\alpha), \bar{X}_2 = \bar{X}_\beta - \bar{A}_2 \cdot (\bar{D}_\beta), \bar{X}_3 = \bar{X}_\delta - \bar{A}_3 \cdot (\bar{D}_\delta) \quad (6)$$

$$\bar{X}(t+1) = \frac{\bar{X}_1 + \bar{X}_2 + \bar{X}_3}{3} \quad (7)$$

شکل ۴ چگونگی به‌روزرسانی موقعیت یک عامل جستجو را در یک فضای جستجوی دوبعدی، با توجه به موقعیت آلفا، بتا و دلتا نشان می‌دهد. مشاهده می‌شود که موقعیت نهایی حاصل شده در مکانی تصادفی و در داخل دایره‌ای قرار دارد که با توجه به موقعیت آلفا، بتا و دلتا تعریف شده است. به‌عبارت‌دیگر آلفا، بتا و دلتا موقعیت شکار را برآورد می‌کنند و دیگر گرگ‌ها موقعیت خود را به‌صورت تصادفی در ناحیه اطراف شکار به‌روزرسانی می‌نمایند.

حمله به طعمه (بهره برداری)

همان‌طور که در بالا ذکر شد، گرگ‌های خاکستری زمانی که شکار متوقف می‌شود به آن حمله کرده و شکار را به پایان می‌رسانند. برای این‌که نزدیک شدن به طعمه را به‌صورت ریاضی مدل کنیم، مقدار \bar{a} را کاهش می‌دهیم. باید توجه داشت که محدوده نوسان \bar{A} نیز توسط \bar{a} کاهش می‌یابد. به‌عبارت‌دیگر \bar{A} مقداری تصادفی

می‌شود که از نزدیک شدن آن‌ها به طعمه با سرعت مناسب جلوگیری می‌نماید. این دقیقاً تأثیر بردار C را بیان می‌کند. بسته به موقعیت یک گرگ، بردار C می‌تواند وزنی^{۴۳} تصادفی به طعمه بدهد تا دستیابی گرگ‌ها به آن سخت‌تر و یا آسان‌تر شود.

به‌طور خلاصه در الگوریتم GWO، فرآیند جستجو با ایجاد یک جمعیت تصادفی از گرگ‌های خاکستری (راه‌حل‌های کاندید) شروع می‌شود. در طول دوره تکرار، گرگ‌های آلفا، بتا و دلتا موقعیت احتمالی شکار را برآورد می‌کنند. هر راه‌حل کاندید فاصله خود را از طعمه به‌روزرسانی می‌نماید. پارامتر a از مقدار ۲ به صفر کاهش پیدا می‌کند تا فرآیند شناسایی و حمله به طعمه را تقویت نماید. زمانی که $|\vec{A}| > 1$ باشد، راه‌حل‌های کاندید واگرا می‌شوند و زمانی که $|\vec{A}| < 1$ باشد به سمت طعمه همگرا می‌گردند. شبه کد الگوریتم GWO در شکل ۶ ارائه شده است [۹].

در بخش بعد بررسی الگوریتم GWO در بهینه‌سازی توابع و دسته‌بندی دادگان سونار خواهیم پرداخت.

انجام آزمایش‌ها و بررسی نتایج

این بخش به بررسی الگوریتم GWO از نظر توانایی در یافتن بهینه اصلی توابع، سرعت همگرایی، دقت دسته‌بندی و کارا بودن الگوریتم در مورد دادگان واقعی خواهد پرداخت.

بهینه‌سازی


در این بخش الگوریتم GWO را توسط ۲۳ تابع معیار، ارزیابی می‌کنیم. این توابع بکار رفته، توابع معیار کلاسیکی هستند که توسط بسیاری از محققان مورد استفاده قرار گرفته‌اند [۱۵-۲۵]. این توابع آزمون را برای مقایسه نتایج خود با نتایج الگوریتم PSO به کار می‌بریم. این توابع معیار در جداول ۱ تا ۳ نشان داده شده‌اند که در آن‌ها عبارت بعد، ابعاد تابع را نشان داده و بازه، مرز فضای جستجوی تابع و f_{min} مقدار بهینه را بیان می‌کند. به‌طور کلی توابع معیار مورد استفاده، توابع حداقل سازی^{۴۴} هستند که می‌توان آن‌ها را به سه گروه تک وضعی^{۴۵}، چند وضعی^{۴۶} و چند وضعی با بعد ثابت^{۴۷} تقسیم‌بندی کرد. لازم به ذکر است شرح مفصلي از توابع معیار مرکب در گزارش تخصصی CEC 2005 در دسترس است [۲۶ و ۲۷].

الگوریتم GWO، ۳۰ بار روی هر تابع معیار اجرا شده است. نتایج آماری (میانگین و انحراف معیار) در جداول ۴ تا ۶ گزارش شده است. همچنین توابع مورد سنجش و نمودار همگرایی الگوریتم‌های

بالین‌حال الگوریتم GWO ممکن است در معرض گیر افتادن در حداقل‌های محلی باشد، بنابراین نیاز به عملگرهای برای جلوگیری از گیر کردن در حداقل‌های محلی است. اگرچه مکانیسم محاصره پیشنهاد شده تا حدی مکانیسم شناسایی را نیز نشان می‌دهد، اما GWO به عملگرهای بیشتری برای ایجاد خاصیت اکتشاف نیاز دارد.

جستجو برای طعمه (شناسایی)

گرگ‌های خاکستری عمدتاً با توجه به موقعیت آلفا، بتا و دلتا به فرآیند جستجو می‌پردازند. آن‌ها برای جستجوی شکار از یکدیگر فاصله گرفته و برای حمله به آن به یکدیگر نزدیک شده و همکاری می‌کنند. برای مدل کردن این واگرایی به‌صورت ریاضی از بردار \vec{A} با مقداری تصادفی بزرگ‌تر از ۱ یا کوچک‌تر از -۱ استفاده می‌کنیم تا عامل جستجو را ملزم به واگرایی و فاصله از طعمه نمائیم [۱۳]. این روال، فرآیند شناسایی را نشان می‌دهد و به الگوریتم GWO اجازه می‌دهد عمل جستجو را به‌طور سراسری انجام دهد. شکل ۵-الف نشان می‌دهد مقدار $|A| > 1$ گرگ‌ها را وادار به واگرایی از طعمه و یافتن شکاری مناسب‌تر می‌کند.



شکل ۵. حمله به طعمه در مقابل جستجو برای شکار

یکی دیگر از اجزای GWO که بر فرآیند شناسایی تأثیر می‌گذارد، مقدار \vec{C} است. همان‌طور که در معادله ۷ دیده می‌شود، بردار \vec{C} مقادیری تصادفی در بازه $[0, 2]$ دارد. این جزء برای شکار وزن‌هایی تصادفی فراهم می‌کند تا تأثیر موقعیت طعمه را در تعیین فاصله در معادله ۵، شدت ($C > 1$) یا ضعف ($C < 1$) بخشد. این جزء همچنین GWO را در بیشتر نشان دادن رفتار تصادفی در طول بهینه‌سازی و به طبع آن اکتشاف بهتر و اجتناب از گیر افتادن در حداقل محلی کمک می‌کند. لازم به ذکر است که C نسبت به A به‌صورت خطی کاهش نمی‌یابد. ما در همه حال به C نیاز داریم تا مقادیری تصادفی فراهم کند و فرآیند شناسایی را نه‌تنها در تکرار اولیه، بلکه در تکرار نهایی اجرا نماید. این مؤلفه در جلوگیری از گیر کردن در حداقل محلی، به‌خصوص در تکرار نهایی بسیار مفید است. بردار C را همچنین می‌توان به‌عنوان تأثیر موانعی در نظر گرفت که از نزدیک شدن به طعمه در طبیعت جلوگیری می‌کنند [۱۳]. به‌طور کلی، موانعی طبیعی در مسیر شکار گرگ‌ها ظاهر

43 Weight

44 Minimization

45 Unimodal

46 Multimodal

47 Fixed-Dimension Multimodal

شناسایی، اجتناب از گیر افتادن در حداقل محلی و بهره‌برداری کمک می‌کند.

GWO و PSO مربوط به آن توابع، در شکل ۷ نمایش داده شده است.

تجزیه و تحلیل فرآیند بهره‌برداری

با توجه به نتایج حاصل از جدول ۴، الگوریتم GWO قادر به ارائه نتایجی بسیار مناسب و قابل رقابت با روش PSO است. لازم به ذکر است که توابع تک وضعی برای محک‌زنی فرآیند بهره‌برداری مناسب هستند. این نتایج نشان می‌دهد با توجه به عملگرهای بهره‌برداری که قبلاً در مورد آن‌ها بحث شد، عملکرد GWO در دستیابی به مقدار بهینه بهتر است.

تجزیه و تحلیل فرآیند شناسایی

در مقایسه با توابع تک وضعی، توابع چندوضعی بهینه‌های محلی زیادی دارند که تعداد آن‌ها با توجه به اندازه ابعاد به صورت نمایی افزایش می‌یابد. این امر باعث می‌شود آن‌ها برای محک‌زنی فرآیند شناسایی یک الگوریتم مناسب باشند. با توجه به نتایج حاصل از جدول ۴ و ۵، الگوریتم GWO قادر به ارائه نتایجی بسیار مناسب و قابل رقابت بر روی توابع چندوضعی است. این نتایج نشان می‌دهد الگوریتم GWO در زمینه فرآیند شناسایی، کارایی بسیار مناسبی دارد.

اجتناب از بهینه محلی

دسته سوم از توابع معیار به کاربرده شده شامل توابع مرکب است که برای آزمون الگوریتم‌های فرا اکتشافی بسیار مناسب است. فرآیند شناسایی و بهره‌برداری را می‌توان توسط توابع مرکب و به صورت هم‌زمان محک‌زد. علاوه بر این، اجتناب از بهینه محلی در یک الگوریتم را می‌توان با توجه به تعداد گسترده بهینه‌های محلی مربوط به این توابع آزمون، مورد بررسی قرار داد. با توجه به جدول ۶، الگوریتم GWO بر روی نیمی از توابع معیار مرکب نسبت به دیگر الگوریتم‌ها عملکرد بهتری دارد. این الگوریتم بر روی مابقی توابع معیار مرکب نیز نتایجی بسیار قابل توجه و رقابتی دارد. این نشان می‌دهد الگوریتم GWO تعادل خوبی بین مراحل اکتشاف و بهره‌برداری ایجاد می‌کند که منجر به اجتناب از گیر افتادن در بهینه محلی می‌شود. این قابلیت ویژه با توجه به مقدار انطباقی^{۴۸} پارامتر A حاصل می‌شود. همان‌طور که قبلاً ذکر شد نیمی از تکرارها به مرحله اکتشاف ($|A| \geq 1$) و بقیه به مرحله بهره‌برداری ($|A| < 1$) اختصاص داده می‌شوند. این مکانیسم به الگوریتم GWO در دستیابی به نتایج مطلوب و مناسب به صورت هم‌زمان در

تجزیه و تحلیل رفتار همگرایی

در این بخش رفتار همگرایی الگوریتم GWO مورد بررسی قرار می‌گیرد. با توجه به بررسی‌های پرگ^{۴۹} و همکارانش [۲۸]، در جابجایی عوامل جستجو در طول مراحل اولیه بهینه‌سازی باید تغییرات ناگهانی وجود داشته باشد. این عامل به الگوریتم فرا اکتشافی در کاوش فضای جستجو به صورت گسترده کمک شایانی می‌کند. در ادامه این تغییرات برای تأکید بر فرآیند بهره‌برداری در پایان بهینه‌سازی، کاهش می‌یابد. به منظور مشاهده رفتار همگرایی الگوریتم GWO، می‌توان شکل ۷ را مشاهده کرد.

```

Initialize the grey wolf population  $X_i$  ( $i = 1, 2, \dots, n$ )
Initialize a, A, and C

Calculate the fitness of each search agent
 $X_\alpha$ =the best search agent
 $X_\beta$ =the second best search agent
 $X_\delta$ =the third best search agent

while (t < Max number of iterations)
  for each search agent
    Update the position of the current search agent by equation (7)
  end for

  Update a, A, and C
  Calculate the fitness of all search agents
  Update  $X_\alpha$ ,  $X_\beta$ , and  $X_\delta$ 
  t=t+1
end while
return  $X_\alpha$ 

```

شکل ۶. شبه کد مربوط به الگوریتم GWO

جدول ۱. توابع معیار تک وضعی

f_{\min}	بازه	بعد	تابع
0	[-100,100]	30	$f_1(x) = \sum_{i=1}^n x_i^2$
0	[-10,10]	30	$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $
0	[-100,100]	30	$f_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$
0	[-100,100]	30	$f_4(x) = \max_i \{ x_i , 1 \leq i \leq n\}$
0	[-30,30]	30	$f_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$
0	[-100,100]	30	$f_6(x) = \sum_{i=1}^n (x_i + 0.5)^2$
0	[-1.28,1.28]	30	$f_7(x) = \sum_{i=1}^n i x_i^4 + \text{random}[0,1]$

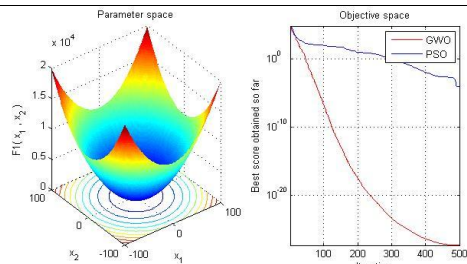
جدول ۲. توابع معیار چند وضعی

f_{\min}	بازه	بعد	تابع
-418.9829×5	[-500,500]	30	$F_8(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$
0	[-5.12,5.12]	30	$F_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$
0	[-32,32]	30	$F_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$
0	[-600,600]	30	$F_{11}(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$
0	[-50,50]	30	$F_{12}(x) = \frac{\pi}{n} \{10 \sin(\pi y_i) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2\} + \sum_{i=1}^n u(x_i, 10, 100, 4)$ $y_i = 1 + \frac{x_i + 1}{4}$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$
0	[-50,50]	30	$F_{13}(x) = 0.1 \{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \} + \sum_{i=1}^n u(x_i, 5, 100, 4)$
-4.678	[-0,π]	30	$F_{14}(x) = -\sum_{i=1}^n \sin(x_i) \cdot \left(\sin\left(\frac{i x_i^2}{\pi}\right) \right)^{2m}, m = 10$
-1	[-20,20]	30	$F_{15}(x) = [e^{-\sum_{i=1}^n (x_i/\beta)^{2m}} - 2e^{-\sum_{i=1}^n x_i^2}] \cdot \prod_{i=1}^n \cos^2 x_i, m = 5$
-1	[-10,10]	30	$F_{16}(x) = \{ [\sum_{i=1}^n \sin^2(x_i)] - \exp(-\sum_{i=1}^n x_i^2) \} \cdot \exp[-\sum_{i=1}^n \sin^2 \sqrt{ x_i }]$

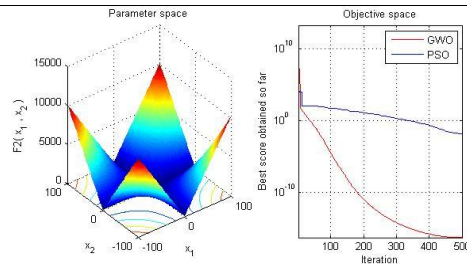
جدول ۳. توابع معیار چند وضعی با بعد ثابت

f_{\min}	بازه	بعد	تابع
1	[-65,65]	2	$F_{14}(x) = \left(\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_j)^6} \right)^{-1}$
0.00030	[-5,5]	4	$F_{15}(x) = \sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$
-1.0316	[-5,5]	2	$F_{16}(x) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$


0.398	[-5,5]	2	$F_{17}(x) = \left(x_2 - \frac{5.1}{4\pi^2}x_1^2 + \frac{5}{\pi}x_1 - 6\right)^2 + 10\left(1 - \frac{1}{8\pi}\right)\cos x_1 + 10$
3	[-2,2]	2	$F_{18}(x) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 - 3x_2)^2 \times (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$
-3.86	[1,3]	3	$F_{19}(x) = -\sum_{i=1}^4 c_i \exp(-\sum_{j=1}^3 a_{ij}(x_j - p_{ij})^2)$
-3.32	[0,1]	6	$F_{20}(x) = -\sum_{i=1}^4 c_i \exp(-\sum_{j=1}^6 a_{ij}(x_j - p_{ij})^2)$
-10.1532	[0,10]	4	$F_{21}(x) = -\sum_{i=1}^5 [(X - a_i)(X - a_i)^T + c_i]^{-1}$
-10.4028	[0,10]	4	$F_{22}(x) = -\sum_{i=1}^7 [(X - a_i)(X - a_i)^T + c_i]^{-1}$
-10.5363	[0,10]	4	$F_{23}(x) = -\sum_{i=1}^{10} [(X - a_i)(X - a_i)^T + c_i]^{-1}$




F₁




F₂




F₃




F₄




F₅




F₆



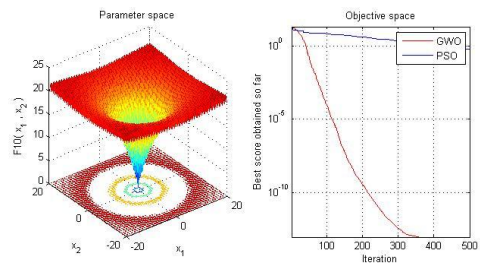
F₇




F₈




F₉




F₁₀




F₁₁




F₁₂




F₁₃




F₁₄




F₁₅



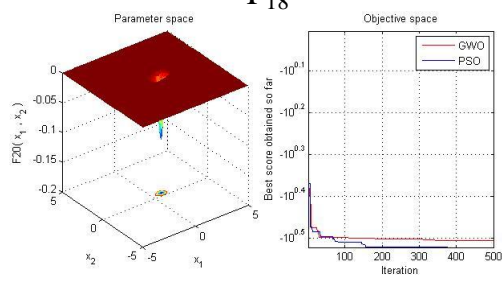
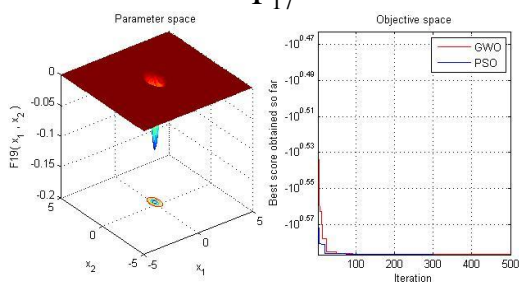
F₁₆

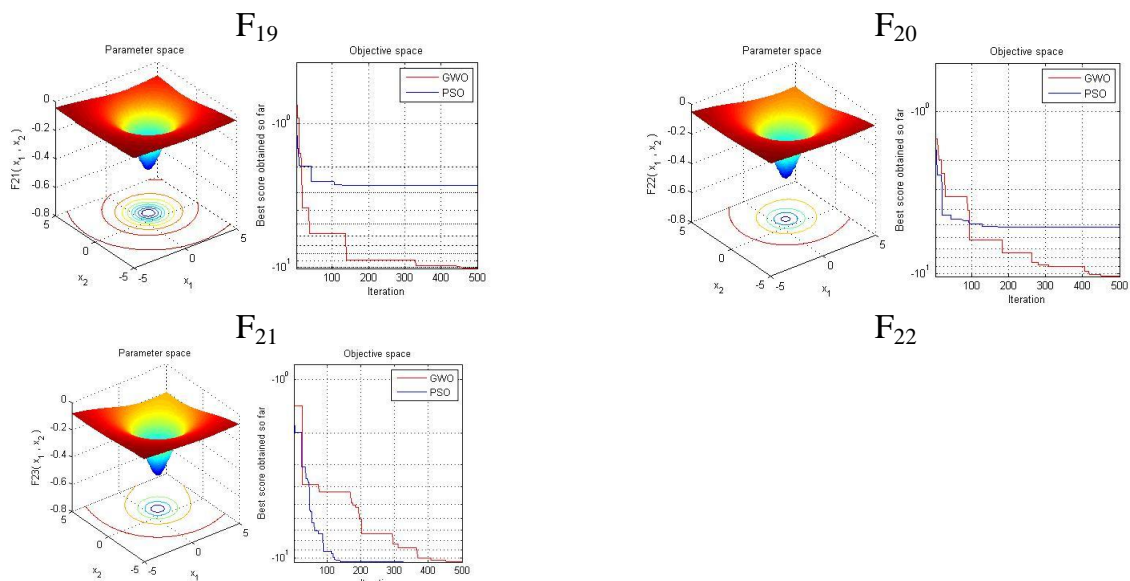


F₁₇



F₁₈





F₂₃

شکل ۷. توابع معیار و نمودار همگرایی حاصل از الگوریتم های PSO و GWO
 جدول ۴. نتایج حاصل از توابع معیار تک وضعی

PSO		GWO		F
Std	Ave	Std	Ave	
0.000202	0.000136	6.34E-05	6.59E-28	F ₁
0.045421	0.042144	0.029014	7.18E-17	F ₂
22.11924	70.12562	79.14958	3.29E-06	F ₃
0.317039	1.086481	1.315088	5.61E-07	F ₄
60.11559	96.71832	69.90499	26.81258	F ₅
8.28E-05	0.000102	0.000126	0.816579	F ₆
0.044957	0.122854	0.100286	0.002213	F ₇

جدول ۵. نتایج حاصل از توابع معیار چند وضعی

PSO		GWO		F
Std	Ave	Std	Ave	
1152.814	-4841.29	-4087.44	-6123.1	F ₈
11.62938	46.70423	47.35612	0.310521	F ₉
0.50901	0.276015	0.077835	1.06E-13	F ₁₀
0.007724	0.009215	0.006659	0.004485	F ₁₁
0.026301	0.006917	0.020734	0.053438	F ₁₂
0.008907	0.006675	0.004474	0.654464	F ₁₃

جدول ۶. نتایج حاصل از توابع معیار چند وضعی با بعد ثابت


PSO		GWO		F
Std	Ave	Std	Ave	
2.560828	3.627168	4.252799	4.042493	F ₁₄
0.000222	0.000577	0.000625	0.000337	F ₁₅
6.25E-16	-1.03163	-1.03163	-1.03163	F ₁₆
0	0.397887	0.397887	0.397889	F ₁₇
1.33E-15	3	3	3.000028	F ₁₈
2.58E-15	-3.86278	-3.86278	-3.86263	F ₁₉
0.060516	-3.26634	-3.25056	-3.28654	F ₂₀
3.019644	-6.8651	-9.14015	-10.1514	F ₂₁
3.087094	-8.45653	-8.58441	-10.4015	F ₂₂
1.782786	-9.95291	-8.55899	-10.5343	F ₂₃

دسته بندی دادگان سونار

در این قسمت به منظور سنجش الگوریتم GWO در زمینه دادگان واقعی، دادگان هدف واقعی و کلاتر سونار فعال با استفاده از یک دسته بندی کننده RBF که توسط الگوریتم GWO آموزش دیده است، دسته بندی می شود. سپس نتایج با دسته بندی کننده ای که با الگوریتم PSO، GSA و الگوریتم ترکیبی PSO/GSA آموزش دیده است، مقایسه می شود.


دادگان سونار

دادگان سونار مورد استفاده در این مقاله از آزمایش Gorman و Sejnowski موجود در مراجع [۳۰ و ۲۹] استخراج شده است. در این آزمایش دو نوع اکو^{۵۰} (سیگنال بازگشتی) وجود دارد، اولی مربوط به یک سیلندر فلزی (نقش هدف واقعی را برعهده دارد) و دومی مربوط به یک صخره ای هم اندازه ای سیلندر (نقش کلاتر یا هدف کاذب را ایفا می کند)، هستند. همان گونه که در شکل ۸ مشاهده می شود، ویژگی هدف واقعی و کلاتر بسیار شبیه هم است و با یک دسته بندی کننده خطی یا غیرخطی مرتبه پایین نمی توان آن ها را از یکدیگر تفکیک کرد (برای قابل مشاهده بودن، دادگان به ۳ بعد کاهش داده شده اند).



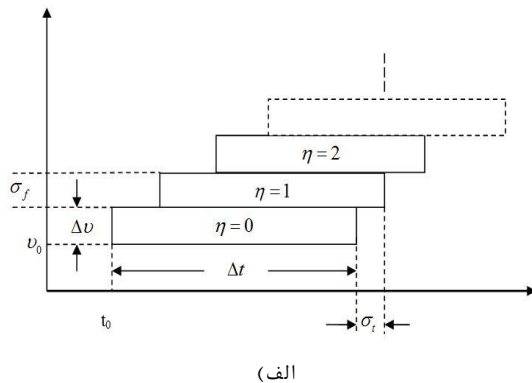
شکل ۸. ترسیم پراکنندگی دادگان سونار.

در این آزمایش یک سیلندر فلزی به طول ۵ فوت و یک صخره هم اندازه با آن در بستر شنی دریا قرار داده شده اند و یک پالس چیرپ FM خطی پهن باند^{۵۱} ($ka=55/6$) به سمت آن ها فرستاده شده است. اکوهای برگشتی در فاصله ۱۰ متری از آن ها جمع آوری شده است. بر اساس SNR اکوی دریافتی، از ۱۲۰۰ اکو جمع آوری شده ۲۰۸ اکو که SNR آن ها بین 4dB تا 15dB است، انتخاب شده اند. از این ۲۰۸ اکو، ۱۱۱ عدد مربوط به سیلندر فلزی و ۹۷ عدد مربوط به صخره هستند. شکل ۹ نمونه هایی از اکوهای دریافتی از صخره و سیلندر فلزی را نشان می دهد.



شکل ۹. نمونه ای از اکوی دریافتی صخره (کلاتر) و هدف واقعی (سیلندر فلزی).

پیش پردازش استفاده شده برای به دست آوردن پوش طیفی در شکل ۱۰ نشان داده شده است. در شکل ۱۰-الف مجموعه ای از درجه های نمونه برداری مشاهده می شود؛ در شکل ۱۰-ب مجموعه ای درجه های نمونه برداری بر روی طیف نگاره دو بعدی تابع فوریه ای اکوی سونار قرار گرفته اند. پوش طیفی توسط جمع آوری اثرات هر درجه به دست می آید. در این آزمایش پوش طیفی از ۶۰ نمونه ی طیفی که بین ۰ و ۱ نرمالیزه شده اند، تشکیل شده است. هر کدام از این اعداد نماینده مجموع انرژی موجود در درجه نمونه برداری مربوطه است؛ به طور مثال انرژی موجود در درجه اول ($\eta = 0$) بعد از نرمالیزه شدن، عدد اول از ۶۰ عدد موجود در بردار ویژگی را تشکیل می دهد.



50 Echo
51 Wide-Band Linear FM

نمایش مسئله‌ی آموزش شبکه‌ی عصبی RBF توسط الگوریتم GWO

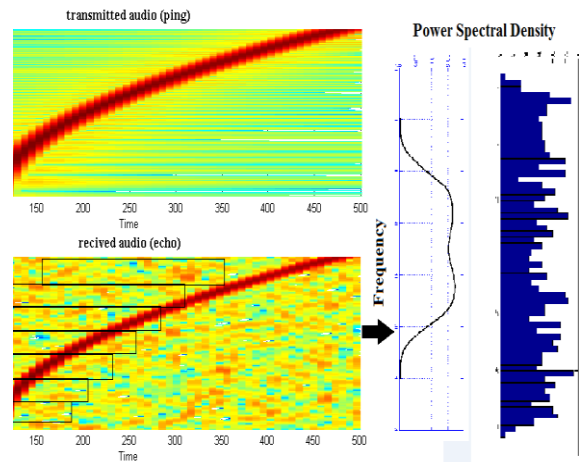
به طور کلی، سه روش برای نمایش ترکیب پارامترهای مجهول وجود دارد: بردار، ماتریس و حالت باینری [۱۱]. در نمایش برداری، هر عنصر با یک بردار نمایش داده می‌شود. برای آموزش یک شبکه‌ی عصبی RBF، باید همه‌ی وزن‌ها، بایاس‌ها، پارامترهای انتشار و مراکز معلوم باشند. در نمایش ماتریسی، هر عنصر به صورت یک ماتریس نمایش داده می‌شود. برای نمایش باینری، هر عنصر به صورت رشته‌ای از بیت‌های باینری نمایش داده می‌شود. هر کدام از این شیوه‌های نمایش، مزایا و معایب خاص خود را دارد که می‌تواند در یک مسئله‌ی خاص مفید واقع گردد [۳۰].

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 برنامه‌ی شبکه‌های عصبی RBF، از جعبه ابزارهای 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 (a)
- بردارهای مرکز لایه پنهان (c)
- پارامترهای بایاس نرون‌های لایه خروجی (β)

تعداد نرون‌های لایه پنهان در شبکه‌های عصبی بسیار مهم است. بکارگیری نرون‌ها بیشتر از آنچه مورد نیاز است منجر به بیش‌آموزش^{۵۲} شبکه، افزایش پیچیدگی ساختاری و زمان اجرای الگوریتم می‌شود. با توجه به مرجع [۳۱] و بررسی‌های به عمل آمده در آن، تعداد نرون‌های لایه مخفی ۹ عدد انتخاب می‌شود. با افزایش بیشتر تعداد نرون‌های لایه مخفی، پیچیدگی مکانی و زمانی شبکه را افزایش می‌دهیم، اما عملکرد شبکه به مقدار قابل توجهی افزوده نمی‌شود. گرگ‌های الگوریتم GWO شامل پارامترهای وزن (\vec{W})، انتشار (\vec{a})، بردارهای مرکز (\vec{c}) و



(ب)


شکل ۱۰. الف) مجموعه‌ای از درجه‌های نمونه برداری و ب) پیش پردازش استفاده شده برای به دست آوردن پوش طیفی.

دسته‌بندی اهداف سوناری

پس از پیش‌پردازش انجام شده بر روی اکوهای بازگشتی سونار و به دست آوردن مجموعه داده نرمالیزه شده بین صفر و یک، مجموعه داده با ابعاد ۲۰۸×۶۰ (۲۰۸ نمونه که هر کدام دارای ۶۰ ویژگی هستند) را به شبکه RBF که توسط الگوریتم‌های PSO, GSA, PSO, PSO و GWO آموزش داده شده است، اعمال می‌شود. بخش بعدی نحوه آموزش شبکه RBF را به منظور دسته بندی دادگان سونار توضیح می‌دهد.

آموزش شبکه‌های عصبی RBF با استفاده از الگوریتم GWO

به طور کلی، سه روش استفاده از الگوریتم‌های تکاملی برای آموزش شبکه‌های عصبی RBF وجود دارد. اولین روش عبارت است از بکارگیری شبکه‌های تکاملی به منظور یافتن ترکیب وزن یال‌ها، بایاس گرهای خروجی، پارامترهای انتشار تابع اساسی و بردارهای مراکز لایه پنهان برای داشتن کمترین مقدار خطا در یک شبکه‌ی عصبی RBF. دومین شیوه عبارت است از بکارگیری شبکه‌های تکاملی به منظور یافتن ساختار مناسب شبکه‌ی عصبی RBF در یک مسئله‌ی خاص و آخرین شیوه شامل بکارگیری شبکه‌های تکاملی به منظور یافتن پارامترهای الگوریتم یادگیری مبتنی بر گرادیان از قبیل نرخ یادگیری و اندازه‌ی حرکت است. در این مقاله، الگوریتم GWO با استفاده از شیوه‌ی نخست به یک شبکه‌ی عصبی RBF اعمال می‌گردد. به منظور طراحی یک الگوریتم آموزش دهنده برای شبکه‌های عصبی RBF، لازم است در الگوریتم GWO، وزن یال‌ها، بایاس گرهای خروجی، پارامترهای انتشار تابع اساسی لایه پنهان و بردارهای مراکز لایه پنهان به صورت مناسب نمایش داده شوند.



شکل ۱۱. نمودار همگرایی حاصل از دسته بندی کننده های مختلف بر روی دادگان سونار.

جدول ۸. نتایج دسته بندی دادگان سونار با استفاده از شبکه RBF آموزش داده شده توسط الگوریتم های مختلف.

الگوریتم	PSO	GSA	PSOGSA	GWO
نرخ دسته بندی	92.2281	93.6741	94.42308	96.66922

نتیجه گیری

در این مقاله از یک روش فرا ابتکاری جدید به نام بهینه ساز گرگ خاکستری (GWO) برای بدست آوردن بهینه اصلی توابع و دسته بندی دادگان واقعی استفاده شد. همان گونه که توضیح داده شد، الگوریتم GWO از سلسله مراتب رهبری و سازوکار شکار گرگ های خاکستری در طبیعت تقلید می کند. در این الگوریتم از چهار نوع گرگ خاکستری شامل آلفا، بتا، دلتا و امگا برای شبیه سازی سلسله مراتب رهبری استفاده شده است. علاوه بر این سه مرحله اصلی شکار شامل جستجوی طعمه، محاصره طعمه و حمله به طعمه شبیه سازی گردیدند. در ادامه الگوریتم مورد نظر توسط ۲۳ تابع آزمون شناخته شده به خوبی ارزیابی شد و نتایج به دست آمده با روش بهینه سازی ازدحام ذرات (PSO) مقایسه گردید. نتایج نشان داد که الگوریتم GWO قادر به ارائه نتایجی بسیار مناسب در نحوه همگرایی و اجتناب از گیر افتادن در بهینه محلی در مقایسه با الگوریتم PSO است. علاوه بر این در این مقاله یک کاربرد واقعی از روش ارائه شده در زمینه دسته بندی دادگان سونار بیان گردید. نتایج حاصله نشان داد که دسته بندی کننده طراحی شده با الگوریتم گرگ خاکستری از نظر دقت دسته بندی دادگان سونار و نمودار همگرایی نتایج بهتری را نسبت به الگوریتم های PSO، GSA،

بردارهای بایاس ($\vec{\beta}$) است. یک گرگ در الگوریتم GWO می تواند به صورت رابطه (۸) بیان شود:

$$P_i = [\bar{w} \ \bar{\alpha} \ \bar{c} \ \vec{\beta}] \quad (8)$$

همانطور که ذکر شد هدف نهایی روش های یادگیری، آموزش شبکه های عصبی مصنوعی است. مهم ترین بخش در یادگیری، فرآیند آموزش است. هر نمونه ی آموزش باید شامل محاسبه ی شاخص مناسب بودن همه ی جرم ها باشد. در این مقاله تابع شاخص مناسب بودن Δ^3 جرم (برای همه ی نمونه های آموزش) به روش مجموع مربعات خطا Δ^4 و به صورت رابطه ۹ محاسبه می گردد:

$$f = E^{SSE} \quad (9)$$

تنظیم پارامترها و انجام آزمایش

پارامترهای مورد نیاز و مقادیر اولیه در جدول ۷ آورده شده اند (پارامترهای شبکه PSOGSA ترکیب الگوریتم های PSO و GSA است، بدین دلیل در جدول آورده نشده است). هر شبکه ۱۰ بار آزمایش شده است. بهترین شبکه ی عصبی آموزش دیده از بین ۱۰ بار اجرا، انتخاب و برای مقایسه به کار گرفته می شود. نرخ دسته بندی و درصد خطای آزمون دو مقیاس برای مقایسه الگوریتم های ذکر شده هستند. برای انجام یک مقایسه ی نسبتاً خوب، هر دو الگوریتم وقتی که حداکثر تعداد تکرار به ۲۵۰ رسید، متوقف می شوند. در نهایت همگرایی نتایج برای انجام مقایسه ای جامع بررسی خواهد شد. نتایج در جدول ۸ نمایش داده شده است. از نقطه نظر آماری، الگوریتم GWO، به اندازه ی کافی توانایی جلوگیری از گیر افتادن در حداقل های محلی را دارد و آهنگ همگرایی آن را می توان در شکل ۱۱ مشاهده کرد. کارایی بهتر الگوریتم GWO در جستجوی همه ی فضای مسئله است.

جدول ۷. پارامترهای مورد نیاز و مقادیر اولیه.

الگوریتم	پارامتر	مقادیر
PSO	ثابت شناختی (C_1)	۱
	ثابت اجتماعی (C_2)	۱
	ثابت محلی (W)	۰.۳
	اندازه جمعیت	۲۰۸
GWC	جانمایی	اتصال کامل
	تعداد گرگ ها	۱۲
	محدوده پایین	۳۰
GSA	محدوده بالا	-۳۰
	حداکثر تعداد تکرار	۲۵۰
	تعداد جرم ها	۳۰
	ثابت گرانشی	۱
	تعداد تکرارها	۲۵۰

53 Fitness Function

54 Sum Squared Error (SSE)

[17] W. Guo, L. Wang and Q. Wu, "An Analysis of the Migration Rates for Biogeography-based Optimization," *Information Science*, Vol.254, pp.111-140, 2014.

[18] S. M. Mirjalili and S. Mirjalili, "Design and Analysis of Oval-Shaped-Hole Photonic Crystal Waveguide Design by MoMIR Framework," *Photonics Technology Letters*, Vol.PP, No.99, 2014.

[19] S. M. Mirjalili, S. Mirjalili and A. Lewis, "A Novel Multi-Objective Optimization Framework for Designing Photonic Crystal Waveguides," *IEEE Photonics Technology Letters*, Vol.26, No.2, pp.146-149, 2014.

[20] S. M. Mirjalili, S. Mirjalili, A. Lewis and K. Abedi, "A Tri-Objective Particle Swarm Optimizer for Designing Line Defect Photonic Crystal Waveguides," *Photonics and Nanostructures Fundamentals and Applications*, Vol.12, No.2, pp.152-163, 2014.

[21] S. Saremi, S. M. Mirjalili and S. Mirjalili, "Unit Cell Topology Optimization of Line Defect Photonic Crystal Waveguide," *Procedia Technology*, Vol.12, pp.174-179, 2014.

[22] S. Saremi, S. M. Mirjalili and S. Mirjalili, "Chaotic Krill Herd Optimization Algorithm," *Procedia Technology*, Vol.12, pp.180-185, 2014.

[23] G. Li, J. Na, D. P. Stoten and X. Ren, "Adaptive Neural Network Feedforward Control for Dynamically Substructured Systems," *IEEE Transactions on Control Systems Technology*, Vol.22, No.3, pp.944-954, 2014.

[24] I. Boussaid, J. Lepagnot and P. Siarry, "A Survey on Optimization Metaheuristics," *Information Sciences*, Vol.237, pp.82-117, 2013.

[25] A. H. Gandomi and A. H. Alavi, "Krill Herd: A New Bio-Inspired Optimization Algorithm," *Communications in Nonlinear Science and Numerical Simulation*, Vol.17, No.12, pp.4831-4845, 2012.

[26] W. T. Pan, "A New Fruit Fly Optimization Algorithm: Taking the Financial Distress Model as an Example," *Knowledge-Based Systems*, Vol.26, pp.69-74, 2012.

[27] J. J. Liang, P. N. Suganthan and K. Deb, "Novel Composition Test Functions for Numerical Global Optimization" *IEEE Swarm Intelligence Symposium*, pp.68-75, 2005.

[28] F. Van, D. Bergh and A. P. Engelbrecht, "A Study of Particle Swarm Optimization Particle Trajectories," *Information Sciences*, Vol.176, No.8, pp.937-971, 2006.

[29] [http://archive.ics.uci.edu/ml/datasets/Connectionist+Benchmark+\(Sonar,+Mines+vs.+Rocks\)](http://archive.ics.uci.edu/ml/datasets/Connectionist+Benchmark+(Sonar,+Mines+vs.+Rocks)).

[30] 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.

[31] S. Mirjalili, "Hybrid Particle Swarm Optimization and Gravitational Search Algorithm for Multilayer Perceptron Learning," *Universiti Teknologi Malaysia (UTM)*, 2011.

و PSO GSA ارائه می کند که این امر به خاطر توانایی این الگوریتم در تنظیم فاز جستجو با فاز بهره برداری است.

مرجع ها

[1] E. Bonabeau, M. Dorigo and G. Theraulaz, "Swarm Intelligence: from Natural to Artificial Systems," Oxford University Press, New York, 1999.

[2] M. Dorigo, M. Birattari and T. Stutzle, "Ant Colony Optimization," *Computational Intelligence Magazine*, Vol.1, No.4, pp.28-39, 2006.

[3] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," *IEEE International Conference on Neural Networks*, Vol.4, pp.1942-1948, 1995.

[4] Y. C. Ho and D. L. Pepyne, "Simple Explanation of the No-Free-Lunch Theorem and Its Implications," *Journal of Optimization Theory and Applications*, Vol.115, No.3, pp.549-570, 2002.

[5] S. Kirkpatrick, C. D. Gelatt and M. P. Vecchi, "Optimization by Simulated Annealing," *Science*, New Series, Vol.220, No.4598, pp.671-680, 1983.

[6] G. Beni and J. Wang, "Swarm Intelligence in Cellular Robotic Systems," *Robots and Biological Systems: Towards a New Bionics?*, Vol.102, pp.703-712, 1993.

[7] D. Karaboga, B. Gorkemli, C. Ozturk and N. Karaboga, "A Comprehensive Survey: Artificial Bee Colony (ABC) Algorithm and Applications," *Artificial Intelligence Review*, Vol.42, No.1, pp.21-57, June 2014.

[8] O. Olorunda and A. P. Engelbrecht, "Measuring Exploration/Exploitation in Particle Swarms using Swarm Diversity," *IEEE World Congress on Computational Intelligence*, pp.1128-1134, 2008.

[9] S. Mirjalili, S. M. Mirjalili and A. Lewis, "Grey Wolf Optimizer," *Advances in Engineering Software*, Vol.69, pp.46-61, 2014.

[10] L. Lin and M. Gen, "Auto-Tuning Strategy for Evolutionary Algorithms: Balancing Between Exploration and Exploitation," *Soft Computing*, Vol.13, No.2, pp.157-168, 2009.

[11] S. Mirjalili and S. Z. M Hashim, "A New Hybrid PSO GSA Algorithm for Function Optimization," *International Conference on Computer and Information Application*, pp.374-377, 2010.

[12] S. Mirjalili, S. Z. M. Hashim and H. M. Sardroudi, "Training Feedforward Neural Networks using Hybrid Particle Swarm Optimization and Gravitational Search Algorithm," *Applied Mathematics and Computation*, Vol.218, No.22, pp.11125-11137, 2012.

[13] L. D. Mech, "Alpha Status, Dominance, and Division of Labor in Wolf Packs," *Canadian Journal of Zoology*, Vol.77, No.8, pp.1196-1203, 1999.

[14] C. Muro, R. Escobedo, L. Spector and R. Coppinger, "Wolf-pack (Canis Lupus) Hunting Strategies Emerge from Simple Rules in Computational Simulations," *Behavioural Processes*, Vol.88, No.3, pp.192-197, 2011.

[15] S. Mirjalili, S. M. Mirjalili and A. Lewis, "Let a Biogeography-based Optimizer Train Your Multi-Layer Perceptron," *Journal of Information Sciences*, Vol.269, pp.188-209, June 2014.

[16] S. Mirjalili, S. M. Mirjalili and X. S. Yang, "Binary Bat Algorithm," *Neural Computing and Applications*, Vol.25, No.3-4, pp.663-681, 2014.

