

طراحی و پیاده‌سازی یک دسته‌بندی کننده دادگان سوناری مبتنی بر شبکه عصبی ادراکی چندلایه آموزش دیده شده با الگوریتم بهینه‌سازی گروهی فیل‌ها

سید محمدرضا موسوی^۱، مسعود کاوه^۲، محمد خویشه^۳، مجید آقابابایی^۳

m_mosavi@iust.ac.ir

۱- استاد دانشکده مهندسی برق، دانشگاه علم و صنعت ایران

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

۳- استادیار دانشکده مهندسی برق، دانشگاه علوم دریایی امام خمینی (ره) نوشهر

چکیده

دسته‌بندی اهداف سوناری به دلیل پیچیدگی فیزیکی و شباهت بسیار زیاد کلاتر با اهداف واقعی در سونار فعال، یکی از مسایل چالش برانگیز برای پژوهشگران این حوزه است. شبکه‌های عصبی ادراکی چندلایه، یکی از کارآمدترین ابزار در دسته‌بندی اهداف می‌باشند. از آموزش می‌توان به عنوان مهم‌ترین بخش این شبکه‌ها اشاره نمود که دقت دسته‌بندی را تا حد زیادی کنترل می‌نماید. در سال‌های اخیر استفاده از الگوریتم‌های فراابتکاری برای آموزش این نوع شبکه‌ها بسیار مرسوم گشته است. هدف این مقاله، استفاده از الگوریتم بهینه‌سازی گروهی فیل‌ها، برای آموزش شبکه عصبی ادراکی چندلایه به منظور دسته‌بندی اهداف سوناری می‌باشد. در طبیعت فیل‌ها به صورت قبیله‌ای زندگی کرده و در هر قبیله یک فیل به عنوان رهبر، مسولیت رهبری گروه را بر عهده دارد. همچنین فیل‌های نر نیز بعد از بزرگ شدن، خانواده خود را ترک می‌نمایند. این دو رفتار می‌تواند با دو عملگر: به روزرسانی قبیله و جدایی، مدل شود. در این الگوریتم، هر فیل می‌تواند با توجه به جایگاه فعلی خود به روز شده و با استفاده از عملگر جدایی، میزان تنوع در جمعیت را بهبود بخشد. به منظور درست‌نمایی نتایج، در این مقاله از سه دادگان با میزان پیچیدگی و اندازه مختلف برای شبیه‌سازی استفاده شده است. همچنین عملکرد الگوریتم بهینه‌سازی گروهی فیل‌ها در آموزش شبکه عصبی با نتایج چند الگوریتم دیگر مقایسه می‌گردد. مقایسه نتایج شبیه‌سازی نشان می‌دهند که روش پیشنهادی در این مقاله، دارای دقت دسته‌بندی بالاتر و سرعت همگرایی بیشتر نسبت به دیگر الگوریتم‌های فراابتکاری مورد استفاده در این مقاله می‌باشد. همچنین این مقاله یک راه کار برای پیاده‌سازی سخت‌افزاری دسته‌بندی کننده پیشنهادی بر روی تراشه FPGA پیشنهاد می‌نماید.

واژگان کلیدی: سونار، آموزش شبکه عصبی، دسته‌بندی اهداف سوناری، الگوریتم بهینه‌سازی گروهی فیل‌ها، FPGA.

تاریخ دریافت مقاله : ۹۶/۰۹/۱۷

تاریخ پذیرش مقاله : ۹۷/۰۲/۱۹

۱- مقدمه

از نویز، طنین و کلاتر می‌توان به‌عنوان اصلی‌ترین منابع سیگنال‌های ناخواسته در محیط زیر آب یاد کرد. به دلیل شباهت زیاد کلاتر به سیگنال اصلی، قرار دادن آن در دسته‌ای متفاوت از سیگنال بازگشتی به نسبت کار مشکلی می‌باشد [۲۰]. شبکه‌های عصبی یکی از پر استفاده‌ترین و کارآمدترین ابزار در دسته‌بندی اهداف می‌باشند. سادگی، هزینه‌ی محاسباتی کم و کارایی بالا، آن‌ها را تبدیل به یک ابزار محاسباتی محبوب ساخته که به‌منظور دسته‌بندی الگو، پیش‌بینی داده و تقریب زدن توابع مورد استفاده قرار می‌گیرند [۳ و ۴]. صرف نظر از کاربردها، توانایی متمایز شبکه‌های عصبی مصنوعی چندلایه، یادگیری می‌باشد [۵].

یادگیری به‌این معنی است که این شبکه‌ها همانند مغز انسان می‌توانند از یک تجربه یا آزمایش یاد بگیرند. این ویژگی (یادگیری) بخش ضروری همه‌ی شبکه‌های عصبی است که ممکن است به دو نوع تقسیم گردد: یادگیری با نظارت^۱ [۶] و یادگیری بدون نظارت^۲ [۷]. برای شبکه‌های عصبی مصنوعی چندلایه (در بیشتر کاربردها)، از الگوریتم‌های پس‌انتشار^۳ به‌پینه‌شده [۸] و یا استاندارد [۹]، به‌عنوان روش یادگیری استفاده می‌گردد که از خانواده‌ی یادگیری با نظارت می‌باشند. الگوریتم پس‌انتشار، بر مبنای گرادیان است که اشکالاتی همچون همگرایی آهسته [۱۰] و بکارگیری در یک محدوده‌ی کوچک [۱۱] را دارد و بنابراین برای کاربردهای عملی قابل اعتماد نیست. هدف نهایی فرآیند یادگیری در شبکه‌های عصبی، پیدا کردن بهترین ترکیب از یال‌های وزن‌دار و بایاس^۴ آن‌ها است به‌طوری‌که در آموزش شبکه و نمونه‌های آزمون، کمترین مقدار خطا را داشته باشیم.

الگوریتم‌های مبتنی بر جستجوی ابتکاری یا اکتشافی^۵ می‌توانند جایگزین مناسبی برای الگوریتم‌های یادگیری مبتنی بر گرادیان باشد [۱۲]، زیرا ماهیت تصادفی این

الگوریتم‌ها اجازه می‌دهد تا حداقل خطای بهتری نسبت به روش‌های مبتنی بر گرادیان داشته باشیم. به‌علاوه، همان طوری که بررسی خواهد شد، نرخ همگرایی الگوریتم جستجوی تکاملی می‌تواند سریع‌تر از الگوریتم پس‌انتشار باشد [۱۳ و ۱۴] که در [۱۵ و ۱۶] عملکرد الگوریتم‌های مختلف در دسته‌بندی دادگان سوناری مورد مقایسه قرار گرفته است. روش‌های تکاملی گوناگونی از قبیل بهینه‌سازی گروهی ذرات^۶ [۱۷]، الگوریتم ژنتیک^۷ [۱۸]، الگوریتم کلونی مورچه‌ها^۸ [۱۹]، الگوریتم‌های تکامل‌پذیر^۹ [۲۰] و الگوریتم PBILL^{۱۰} برای آموزش شبکه‌های عصبی بکار گرفته شده است [۲۱-۲۴].

در طبیعت فیل‌ها به‌صورت گروهی زندگی کرده و هر گروه از فیل‌ها از مجموعه‌ای از قبیله‌ها^{۱۱} تشکیل می‌گردد. فیل‌ها در هر قبیله تحت رهبری یک سرگروه^{۱۲} زندگی نموده و فیل‌های نر، در سنین جوانی قبیله را ترک می‌نمایند.

در این مقاله، بر مبنای رفتار جمعی فیل‌ها یک الگوریتم بهینه‌سازی مبتنی بر ذرات جدید به نام الگوریتم بهینه‌سازی گروهی فیل‌ها^{۱۳}، برای آموزش شبکه عصبی به منظور دسته‌بندی دادگان پیشنهاد می‌گردد. چرا که این نوع رفتار اجتماعی فیل‌ها می‌تواند برای حل مسائل بهینه‌سازی مورد استفاده قرار گرفته و با دو عملگر به‌روزرسانی قبیله^{۱۴} و جدایی^{۱۵} مدل شود. در این الگوریتم، هر فیل با استفاده از عملگر به‌روزرسانی قبیله، موقعیت خود را با استفاده از موقعیت قبلی و موقعیت سرگروه، به‌روزرسانی می‌نماید [۲۵]. سازمان‌دهی مقاله به شرح زیر است:

بخش دوم به توضیح الگوریتم بهینه‌سازی گروهی فیل‌ها می‌پردازد. بخش سوم و چهارم به ترتیب، دادگان سونار و نحوه آموزش شبکه عصبی را شرح می‌دهد. در بخش پنجم شبیه‌سازی و مقایسه نتایج و در بخش ششم نتیجه‌گیری قرار می‌گیرند.

⁹ Evolutionary Strategies (ES)

¹⁰ Population Based Incremental Learning

¹¹ Clans

¹² Matriarch

¹³ Elephant Herding Optimization (EHO)

¹⁴ Clan Updating Operator

¹⁵ Separating Operator

¹ Supervised Learning

² Unsupervised Learning

³ Back-Propagation (BP) Algorithm

⁴ Bias

⁵ Heuristic Optimization Methods

⁶ Particle Swarm Optimization (PSO)

⁷ Genetic Algorithm (GA)

⁸ Ant Colony Optimization (ACO)

۲- الگوریتم بهینه‌سازی گروهی فیل‌ها

در طبیعت فیل‌ها به صورت گروهی زندگی کرده و ساختار اجتماعی پیچیده‌ای متشکل از فیل‌های نر و ماده دارند. یک گروه از فیل‌ها از چندین خانواده یا قبیله تشکیل شده که تحت سرپرستی یک فیل (معمولا پیرترین فیل ماده) به‌عنوان رهبر قرار دارد.

یک خانواده از یک یا چندین فیل ماده و چندین فیل نابالغ تشکیل می‌شود. بر خلاف فیل‌های ماده که اصرار بر زندگی با اعضای خانواده را دارند، فیل‌های نر ترجیح می‌دهند که در تنهایی به زندگی ادامه داده و در سنین جوانی خانواده را ترک می‌نمایند. هرچند که این فیل‌ها می‌توانند با ارتعاشات فرکانس پایین با خانواده خود در تماس باشند. در این مقاله، زندگی گروهی فیل‌ها تحت تاثیر دو عملگر به‌عنوان یک روش بهینه‌سازی چندمنظوره مورد استفاده قرار می‌گیرد که به این منظور می‌توان از سه قانون کلی زیر بهره برد:

(۱) هر جمعیت یا گروه از فیل‌ها از چند خانواده تشکیل شده که هر خانواده را تعداد ثابتی از فیل‌ها تشکیل می‌دهند.

(۲) در هر نسل، تعداد ثابتی از فیل‌ها خانواده خود را ترک کرده و به دور از خانواده خود به زندگی ادامه می‌دهند.

(۳) در هر خانواده، فیل‌ها تحت رهبری یک رهبر یا سرگروه زندگی می‌کنند.

در ادامه الگوریتم بهینه‌سازی گروهی فیل‌ها مورد بررسی قرار می‌گیرد.

۲-۱- عملگر به‌روزرسانی قبیله

همانطور که در بخش‌های قبل ارائه شده، فیل‌ها در هر قبیله تحت سرپرستی یک سرگروه قرار دارند. بنابراین موقعیت بعدی هر فیل در قبیله c_i تحت تاثیر سرگروه قبیله c_i قرار دارد. بنابراین برای j -امین فیل در قبیله c_i داریم:

$$x_{new,c_i,j} = x_{c_i,j} + \alpha \times (x_{best,c_i} - x_{c_i,j}) \times r \quad (1)$$

که در آن $x_{c_i,j}$ و $x_{new,c_i,j}$ به ترتیب موقعیت جدید و قبلی j -امین فیل در قبیله c_i ، $\alpha \in [0,1]$ یک ضریب مقیاس که میزان تاثیرگذاری سرپرست گروه را در به‌روزرسانی بقیه اعضا نشان می‌دهد و r یک عدد تصادفی

بین صفر و یک می‌باشد. x_{best,c_i} همان سرپرست قبیله است که در واقع مناسب‌ترین پاسخ در حل مساله بهینه‌سازی می‌باشد. سرپرست قبیله یا همان مناسب‌ترین فیل در هر قبیله، نمی‌تواند طبق رابطه (۱) موقعیت خود را به‌روز نموده و از رابطه (۲) استفاده می‌کند.

$$x_{new,c_i,j} = \beta \times x_{center,c_i} \quad (2)$$

که در آن $\beta \in [0,1]$ یک ضریب مقیاس که میزان تاثیرگذاری x_{center,c_i} را در $x_{new,c_i,j}$ نشان می‌دهد. طبق رابطه (۲) مشخص است که $x_{new,c_i,j}$ با استفاده اطلاعات موجود از تمامی فیل‌ها در قبیله c_i به‌دست آمده است. x_{center,c_i} در واقع مرکز قبیله c_i است که برای یک مساله D بعدی می‌تواند از طریق رابطه زیر محاسبه شود:

$$x_{center,c_i} = \frac{1}{n_{c_i}} \times \sum_{j=1}^{n_{c_i}} x_{c_i,j,d} \quad (3)$$

که در آن $1 \leq d \leq D$ نشان دهنده d -امین بعد است. n_{c_i} نشان دهنده تعداد فیل‌ها در قبیله c_i و $x_{c_i,j,d}$ نشان دهنده d -امین بعد از فیل $x_{c_i,j,d}$ می‌باشد. با توجه مطالب و روابط ذکر شده، عملگر به‌روزرسانی قبیله می‌تواند طبق الگوریتم موجود در شکل (۱) نمایش داده شود.

۲-۲- عملگر جدایی

در هر قبیله از فیل‌ها، فیل‌های نر وقتی که به سن بلوغ می‌رسند، خانواده خود را ترک نموده و به زندگی در تنهایی ادامه می‌دهند. این جدایی به‌عنوان عملگر جدایی برای الگوریتم گروهی فیل‌ها مدل شده و در حل مسائل بهینه‌سازی به کار می‌رود. به منظور افزایش و بهبود توانایی قدرت جستجو در این الگوریتم، یک راه حل با کمترین مقدار تابع شایستگی را می‌توان به صورت رابطه (۴) در هر نسل به‌روزرسانی نمود:

$$x_{worst,c_i} = x_{min} + (x_{max} - x_{min} + 1) \times r \quad (4)$$

در رابطه فوق، x_{min} و x_{max} به ترتیب کران بالا و پایین موقعیت فیل‌ها در قبیله c_i ، x_{worst,c_i} بدترین موقعیتی که یک فیل می‌تواند در قبیله داشته باشد و r یک عدد تصادفی بین صفر و یک را نشان می‌دهد. شکل (۲) شبه کد مربوط به نحوه عملکرد عملگر جدایی را به تصویر می‌کشد. همچنین نحوه عملکرد الگوریتم گروهی فیل‌ها، در شبه کد شکل (۳) قابل مشاهده می‌باشد.

```

for  $c_i=1$  to nClan (for all clans in elephant population) do
  for  $j=1$  to  $n_{c_i}$  (for all elephants in clan  $c_i$ ) do
    Update  $x_{c_i,j}$  and generate  $x_{new,c_i,j}$  by Eq. (1);
    if  $x_{c_i,j} = x_{best,c_i}$  then
      Update  $x_{c_i,j}$  and generate  $x_{new,c_i,j}$  by Eq. (2);
    end if
  end for
end for

```

شکل (۱) شبه کد مربوط به عملگر به روزرسانی قبیله.

```

for  $c_i=1$  to nClan (for all clans in elephant population) do
  Replace the worst elephant in clan  $c_i$  by Eq. (4).
end for

```

شکل (۲) شبه کد مربوط به عملگر جدایی.

Step 1: Initialization

Step 2: While $t < \text{MaxGen}$ **do**

Sort all the elephants according to their fitness;
 Implement clan updating operator by Figure 1;
 Implement separating operator as shown in Figure 2;
 Evaluate population by the newly updated positions;
 $t=t+1$;

end while

شکل (۳) شبه کد مربوط به به روزرسانی قبیله.

شده است [۲۴]. همچنین دیگر ویژگی‌های محیطی مانند چگالی، دما، غلظت آب، سرعت باد و غیره از سونوبوی لرزه‌نگاری^۱ مربوط به سازمان بنادر و دریانوردی به دست آمده است. شکل (۴) سونوبوی‌های به کار رفته در این آزمایش را برای استخراج دادگان سونار نشان می‌دهد.

۳- دادگان سونار

دادگان عملی سونار مورد استفاده در این مقاله از آزمایش انجام شده در سواحل دانشگاه علوم دریایی امام خمینی (ره) نوشهر در عمق حدود ۴۰ تا ۱۰۰ متر توسط سونوبوی طراحی شده در آزمایشگاه سونار این دانشگاه استخراج



ب) سونوبوی طراحی شده.



الف) سونوبوی لرزه‌نگاری.

شکل (۴) سونوبوی‌های به کار رفته برای استخراج دادگان سونار.

¹ Seismographic Buoy

ج) حذف مصنوعی و چند مسیره^۲: در این مرحله، به وسیله همبستگی متقابل سیگنال ارسالی، موقعیت بیشینه مقدار خروجی فیلتر همسانی^۴ (x) در هر زاویه مشخص می‌گردد. سپس یک پنجره با پوشش [x-left: x-right] به سیگنال اعمال می‌شود که در آن left=211 و right=300 است.

۳-۲- استخراج ویژگی

پس از فشرده‌سازی، صوت‌های آشکار شده وارد مرحله استخراج ویژگی شده و طیف انرژی با استفاده از رابطه زیر محاسبه می‌شود:

$$|s(k)|^2 = s_r^2(k) + s_i^2(k) \quad (5)$$

که در آن، $s_r^2(k)$ و $s_i^2(k)$ به ترتیب مقادیر حقیقی و موهومی تبدیل فوریه سیگنال آشکار شده می‌باشند. سپس طیف انرژی از فیلتر مل^۵ عبور کرده و خروجی انرژی 1- امین فیلتر طبق رابطه (۶) به دست می‌آید.

$$E(l) = \sum_{k=0}^{N-1} |s(k)|^2 H_l(k) \quad (6)$$

که در آن N تعداد فرکانس‌های انتخابی است که در تبدیل فوریه سریع پیش‌پردازش مورد استفاده قرار گرفته و $H_l(k)$ تابع تبدیل فیلتر بوده که در آن $l = 0, 1, \dots, M$ می‌باشد.

در نهایت ضرایب فرکانسی فیلتر مل^۶ به وسیله تبدیل کسینوسی گسسته^۷ در حوزه زمان، از طریق رابطه زیر محاسبه می‌شود:

$$c(n) = \sum_{l=1}^M e(l) \cos(n(\log(E(l)) - 0.5) \frac{\pi}{M}) \quad (7)$$

در نهایت برای هر هدف آشکار شده، بردار ویژگی به صورت زیر به دست می‌آید:

$$X_m = [c(0), c(1), \dots, c(p-1)]^T \quad (8)$$

تمامی مراحل فوق در محیط XSG سخت‌افزار FPGA پیاده‌سازی شده‌اند. شکل‌های (۵) و (۶) به ترتیب تمامی مراحل پیش‌پردازش و استخراج ویژگی و مدل کلی پیاده‌سازی آن‌ها در FPGA را نشان می‌دهند. در شکل (۶) استخراج ویژگی بر پایه تبدیل فوریه و MFCC انجام شده یک شبکه عصبی به عنوان دسته‌بندی کننده در سیستم (شناسنده الگو^۸) قرار می‌گیرد.

در این آزمایش دو نوع اکو (سیگنال بازگشتی) وجود دارد: اولی مربوط به یک سیلندر فلزی (نقش هدف واقعی را برعهده دارد) و دومی مربوط به یک صخره‌ی هم اندازه‌ی سیلندر (نقش کلاتر یا هدف کاذب را ایفا می‌کند) می‌باشند. ویژگی‌های فرکانسی هدف واقعی و کلاتر بسیار شبیه هم می‌باشد و با یک دسته‌بندی کننده خطی یا غیرخطی مرتبه پایین نمی‌توان آن‌ها را از یکدیگر تفکیک کرد. لذا هدف این مقاله، طراحی یک دسته‌بندی کننده دادگان سونار با استفاده از شبکه عصبی ادراکی چندلایه می‌باشد. در این آزمایش یک سیلندر فلزی به طول ۲ متر و یک صخره هم‌اندازه با آن در بستر شنی دریا قرار داده شده‌اند و یک پالس چیرپ FM خطی پهن باند ($ka=55/6$) 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 ۲۰۰ اکو که SNR آن‌ها بین 8dB تا 15dB است، انتخاب شده‌اند. از این ۲۰۰ اکو، ۱۱۰ عدد مربوط به سیلندر فلزی و ۹۰ عدد مربوط به صخره هستند. مراحل کلی کار بر روی دادگان سونار شامل سه مرحله پیش‌پردازش، استخراج ویژگی و دسته‌بندی می‌باشد.

۳-۱- پیش‌پردازش

به دلیل داده‌های خام بسیار زیادی که از حسگرها در گیرنده به دست می‌آیند، نیاز به محاسبات بسیار زیاد و پیچیده به دور از انتظار نخواهد بود. لذا برای کمینه شدن حجم محاسبات، ابتدا لازم است تا مراحل ماند پیش‌پردازش و استخراج ویژگی قبل از دسته‌بندی اهداف پیش‌بینی شوند.

الف) مقیاس‌گذاری^۱: این مرحله خیل داده‌های دریافتی را به سیگنال‌های مقیاس‌بندی شده تبدیل می‌کند.

ب) نمونه‌برداری به پایین^۲: نرخ اصلی نمونه‌برداری برابر ۲ مگاهرتز بوده که از پهنای باند سیگنال اصلی بیشتر است. تعداد نمونه‌های ثابتی در مرحله نمونه‌برداری انتخاب می‌شوند. در این مقاله تعداد این نمونه‌ها برابر ۲۰۴۸ است.

¹ Scaling

² Down Sampling

³ Multi-path and Artificial Elimination

⁴ Matched Filter

⁵ Mel Filter

⁶ Mel-Frequency Cepstral Coefficients (MFCCs)

⁷ Discrete Cosine Transform (DCT)

⁸ Pattern Recognizer

۴- آموزش شبکه عصبی

شکل (۷) یک شبکه عصبی ادراکی چند لایه را نشان می‌دهد که دارای p گره ورودی، q نرون در لایه مخفی و r نرون در لایه خروجی است. ز-امین تحریک لایه مخفی از رابطه زیر به دست می‌آید:

$$v_j = \sum_{i=1}^p x_i \times w_{ji} + \theta_j, \quad j = 1, 2, \dots, q \quad (9)$$

$$s_j = \text{sigmoyd}(v_j) = \frac{1}{1 + \exp(-v_j)} \quad (10)$$

که در آن، x_i -امین گره در لایه ورودی، w_{ji} وزن یال ارتباطی بین i -امین گره در لایه ورودی و j -امین نرون در

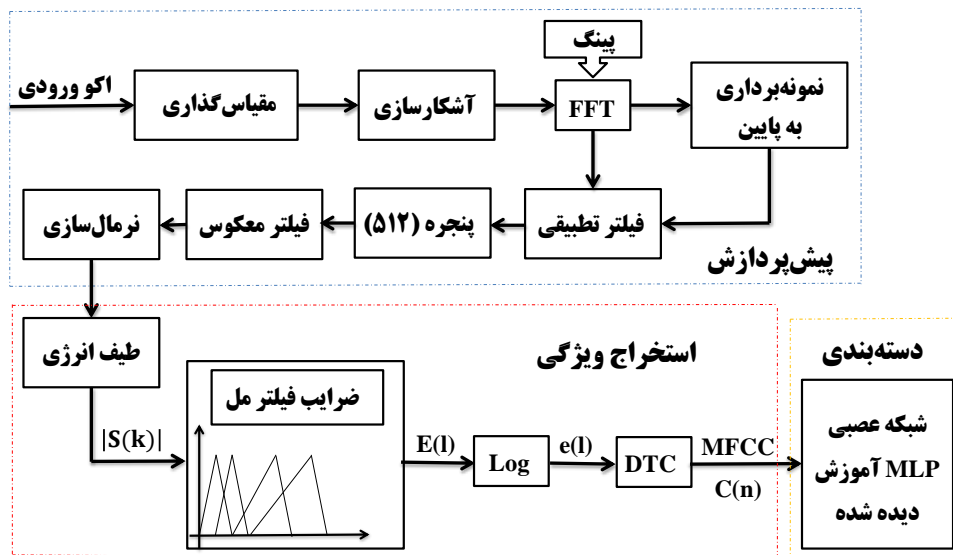
لایه مخفی و θ_j حد آستانه ز-امین نرون در لایه مخفی

است. برای محاسبه خروجی شبکه، روابط زیر را داریم:

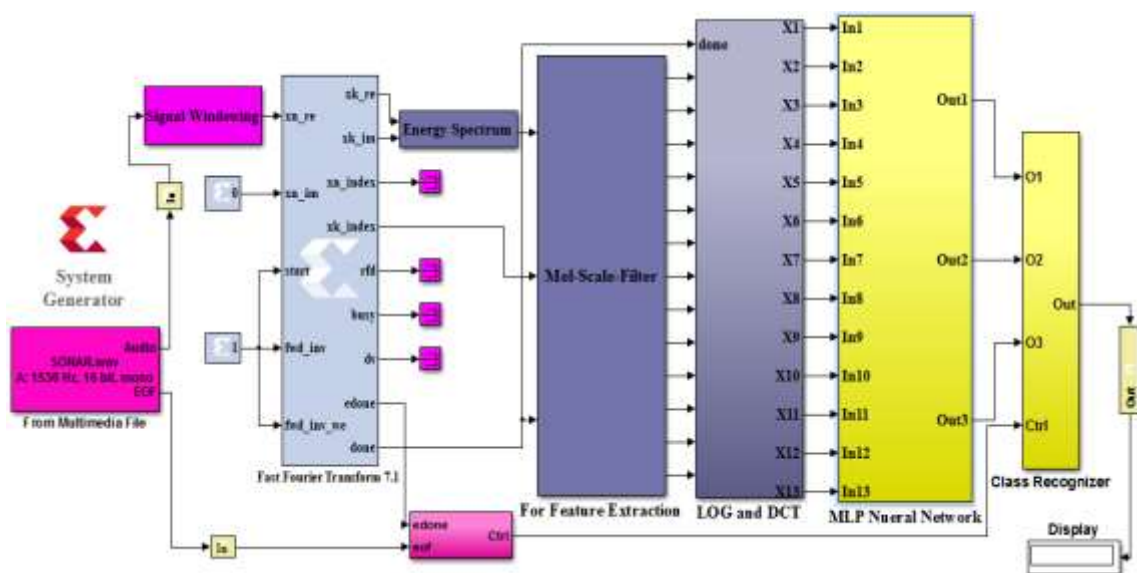
$$z_k = \sum_{j=1}^q s_j \times w_{kj} + \varphi_k, \quad k = 1, 2, \dots, r \quad (11)$$

$$y_k = \text{sigmoyd}(z_k) = \frac{1}{1 + \exp(-z_k)} \quad (12)$$


که در آن، w_{kj} وزن یال ارتباطی بین j -امین نرون در لایه مخفی و k -امین نرون در لایه خروجی و φ_k حد آستانه k -امین نرون در لایه خروجی می‌باشند. همان‌طور که می‌دانید محاسبه وزن‌ها و بایاس‌ها مهم‌ترین بخش هر شبکه عصبی است که در واقع خروجی شبکه عصبی را تعیین می‌کنند.



شکل (۵) نمایی از تمامی مراحل پردازش و پیش‌پردازش بر روی دادگان سونار.



شکل (۶) نمای کلی پیاده‌سازی مراحل پردازش و پیش‌پردازش بر روی دادگان سونار.



شکل (۷) یک شبکه عصبی ادراکی چندلایه با یک لایه مخفی.

متوسط (گلیبرگ^۳) [۳] و دادگان عملی مورد استفاده در این مقاله با ابعاد بالا (سونار). داده‌ها در قسمت‌های بعدی بررسی می‌شوند و ویژگی‌های اولیه آن‌ها در جدول (۱) در دسترس می‌باشد. در هر قسمت الگوریتم بهینه‌سازی گروهی فیل‌ها در موارد دقت دسته‌بندی^۴، سرعت همگرایی^۵ و قابلیت اجتناب از گیر کردن در کمینه‌های محلی^۶ با دیگر الگوریتم‌های نامبرده، در غالب شکل‌ها و جدول‌ها مقایسه می‌شوند. پارامترهای مهم و مقادیر اولیه الگوریتم‌ها در جدول (۲) قابل مشاهده می‌باشند. همچنین شبیه‌سازی انجام شده (با نرم افزار Matlab ۲۰۱۳) در هر قسمت مورد تحلیل قرار می‌گیرد.

۵-۱- دادگان گلیبرگ

این دادگان دارای ۱۵۰ نمونه و ۴ ویژگی است که عبارتند از: طول گلیبرگ، پهناي گلیبرگ، طول کاسبرگ و پهناي کاسبرگ. همچنین دادگان گلیبرگ می‌تواند به سه دسته، دسته‌بندی گردد. برای دسته‌بندی این دادگان از یک شبکه عصبی ادراکی چند لایه با ساختار (۴،۹،۳) استفاده شده است. شکل (۸) و جدول (۳) نتایج عملکرد الگوریتم‌های مختلف برای آموزش شبکه عصبی و دسته‌بندی دادگان گلیبرگ نشان می‌دهد.

شکل (۸) نشان می‌دهد که الگوریتم بهینه‌سازی گروهی فیل‌ها دارای نرخ دسته‌بندی بالاتری نسبت به دیگر الگوریتم‌های تکاملی می‌باشد. همچنین با توجه به جدول (۳) می‌توان دید که الگوریتم بهینه‌سازی گروهی فیل‌ها، بهترین عملکرد را در اجتناب از گیر کردن در کمینه‌های محلی از خود نشان می‌دهد.

در این مقاله، وزن‌ها و بایاس‌های یک شبکه عصبی به عنوان فیل در نظر گرفته شده و مجموعه‌ای از این وزن‌ها که در واقع نشان دهنده یک شبکه عصبی می‌باشند، تشکیل یک قبيله را می‌دهند. الگوریتم بهینه‌سازی گروهی فیل‌ها با تشکیل یک جمعیت اولیه و اعمال عملگرهای خود در تعدادی نسل مشخص، وزن‌ها و حدود آستانه را به‌روز می‌نماید تا در نهایت بهترین جواب با بهینه‌ترین مقادیر پارامترهای شبکه عصبی به‌دست آیند. تابع هدف برای این الگوریتم به صورت میانگین مربعات خطا^۱ بوده و از رابطه زیر محاسبه می‌شود:

$$\sum_{k=1}^q \frac{\sum_{i=1}^m (o_i^k - d_i^k)^2}{q} \quad (13)$$

که در آن، q مبین تعداد نمونه‌های آموزش، m مبین تعداد خروجی‌ها، d_i^k مبین خروجی مطلوب از i-امین ورودی است، وقتی که k-امین نمونه‌ی آموزش استفاده گردد و o_i^k مبین خروجی واقعی در ازای i-امین ورودی است، وقتی که k-امین نمونه‌ی آموزش به ورودی اعمال می‌گردد.

۵- شبیه‌سازی و مقایسه نتایج

در این بخش کارآیی الگوریتم بهینه‌سازی گروهی فیل‌ها، ضمن مقایسه با چند الگوریتم پایه دیگر جهت آموزش شبکه عصبی برای دسته‌بندی اهداف مورد بررسی قرار می‌گیرد. این الگوریتم‌ها عبارتند از الگوریتم ژنتیک، الگوریتم ازدحام ذرات، الگوریتم کلونی مورچه، استراتژی تکاملی و الگوریتم یادگیری افزایشی مبتنی بر جمعیت. برای معتبر بودن ارزیابی و شبیه‌سازی و جامع بودن مقایسه‌ها، سه نوع مختلف از داده‌ها مورد بررسی قرار می‌گیرند: دادگان با ابعاد کم (لنز^۲)، دادگان با ابعاد

⁵ Convergence Speed

⁶ Probability of Getting Stuck in the Local Minimums

¹ Mean Squared Error (MSE)

² Lenses Dataset

³ Iris Dataset

⁴ Classification Accuracy

۲-۵- دادگان لنز

این دادگان از ۲۴ نمونه تشکیل شده است که به دسته زیر تقسیم می‌شود: الف) بیمار باید از لنزهای تماسی سخت استفاده کند، ب) بیمار باید از لنزهای تماسی نرم استفاده کند و ج) بیمار نیازی به استفاده از لنز تماسی ندارد. برای

دسته‌بندی این دادگان از یک شبکه عصبی ادراکی چند لایه با ساختار (۴،۹،۳) استفاده شده است. شکل (۹) و جدول (۴) نتایج عملکرد الگوریتم‌های مختلف برای آموزش شبکه عصبی و دسته‌بندی دادگان گلبرگ را نشان می‌دهد.

جدول (۱) دادگان مورد استفاده به منظور دسته‌بندی اهداف.

نام	کاربرد	نوع داده	Attribute Characteristics	Attributes	ابعاد	سال
Iris	Classification	Multivariate	Real	4	150	1988
Sonar	Classification	Multivariate	Real	4	200	2015
Lenses	Classification	Multivariate	Categorical	4	24	1990

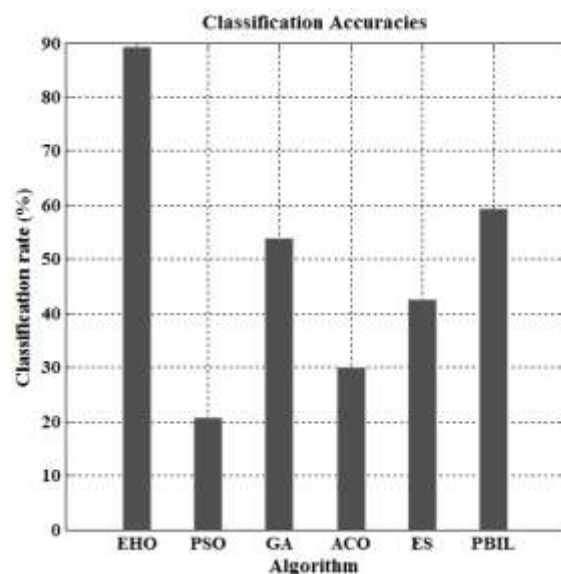
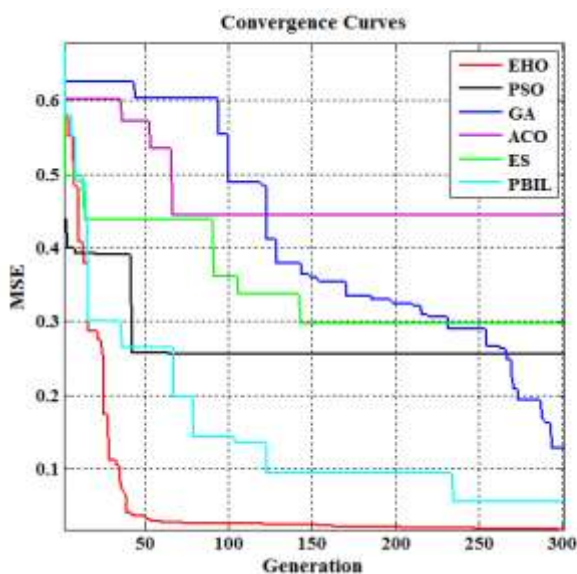
جدول (۲) پارامترها و مقادیر اولیه الگوریتم‌های مورد استفاده.

مقدار	پارامتر	الگوریتم
۰/۵	ضریب مقیاس (α)	EHO
۰/۱	ضریب مقیاس (β)	
۵	جمعیت هر قبیله (nClan)	
۲۰۰	جمعیت	
۳۰۰	تعداد نسل	
اتصال کامل	جانمایی	PSO
۱	ثابت شناختی (C_1)	
۱	ثابت اجتماعی (C_2)	
۰,۳	ثابت محلی (W)	
کد شده واقعی	نوع	GA
چرخ رولت	انتخاب	
تک نقطه‌ای (۱)	ادغام	
یکنواخت (۰,۰۱)	جهش	
۲۰۸	اندازه جمعیت	
۰,۰۰۰۰۰۱	فرمون اولیه (τ_0)	ACO
۲۰	ثابت بروزرسانی فرمون (Q)	
۱	ثابت فرمون (q_0)	
۰,۹	نرخ کاهش فرمون عمومی (p_g)	
۰,۵	نرخ کاهش فرمون محلی (p_l)	
۱	حساسیت فرمون (α)	
۵	حساسیت قابل رویت	
۱۰	λ	ES
۱	σ	
۵	حساسیت قابل رویت	
۰,۰۵	نرخ یادگیری	PBIL
۱	عضو خوب جمعیت	
۰	عضو بد جمعیت	
۰,۱	احتمال جهش	

۵-۳- دادگان سونار

با توجه به شکل (۱۰) مشخص است که الگوریتم گروهی فیلها، بهترین عملکرد را در آموزش شبکه عصبی برای دسته‌بندی دادگان سونار با نرخ دسته‌بندی نزدیک به ۹۰٪ دارد. همچنین جدول (۵) نیز نشان می‌دهد که این الگوریتم دارای بیشترین ظرفیت برای اجتناب از گیر کردن در کمینه‌های محلی می‌باشد. لذا با استفاده از این الگوریتم می‌توان به یک دسته‌بندی‌کننده مطلوب دست پیدا نمود.

با توجه به شکل (۹) مشخص است که الگوریتم بهینه‌سازی گروهی فیلها دارای بیشترین دقت دسته‌بندی و سریع‌ترین نرخ همگرایی می‌باشد. به طوری که این مقدار در درصد دسته‌بندی به بیشینه مقدار خود رسیده است (۱۰۰٪). این میزان دقت دسته‌بندی نشان دهنده توانایی این الگوریتم در دسته‌بندی دادگان با ابعاد و پیچیدگی کم می‌باشد. دلیل این توانایی دسترسی الگوریتم به تمام فضای جست‌وجو و استفاده از عملگر به‌روزرسانی است. همچنین جدول (۴) نشان می‌دهد که این الگوریتم بیشترین قابلیت را در اجتناب از گیر کردن در بهینه‌های محلی نسبت به دیگر الگوریتم‌های فراابتکاری دارد.




شکل (۸) نرخ دسته‌بندی و سرعت همگرایی دسته‌بندی دادگان گلبرگ برای الگوریتم EHO و دیگر الگوریتم‌ها.

جدول (۳) مقایسه الگوریتم EHO با دیگر الگوریتم‌ها برای دادگان گلبرگ.

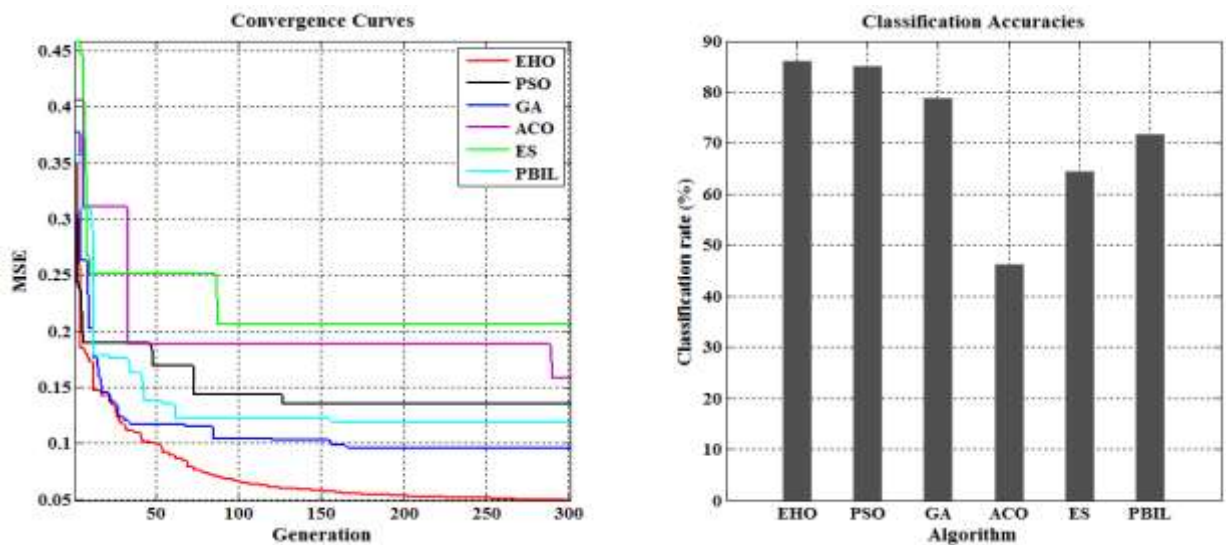
الگوریتم	MSE (Mean)	MSE (Variance)	P-value	نرخ دسته‌بندی
EHO	0.017782	0.0122	1	89%
PSO	0.21699	8.7856e-04	1.0036e-79	21.66%
GA	0.029971	0.0380	3.8153e-68	53.33%
ACO	0.4459	3.9371e-05	2.9159e-91	30%
ES	0.27667	0.0035	9.0945e-82	42.33%
PBIL	0.13189	0.0135	4.6932e-73	58.66%

جدول (۴) مقایسه الگوریتم EHO با دیگر الگوریتم‌ها برای دادگان لنز.

الگوریتم	MSE (Mean)	MSE (Variance)	P-value	نرخ دسته‌بندی
EHO	0.0535	0.0134	1	100%
PSO	0.2371	9.0770e-04	4.2359e-72	62.50%
GA	0.3189	0.0214	1.0281e-75	75.00%
ACO	0.4723	5.9927e-04	3.5704e-97	25.00%
ES	0.3849	0.0046	1.1518e-86	70.83%
PBIL	0.2256	0.0107	2.9047e-64	50.00%



شکل (۹) نرخ دسته‌بندی و سرعت همگرایی دسته‌بندی دادگان لنز برای الگوریتم EHO و دیگر الگوریتم‌ها.



شکل (۱۰) نرخ دسته‌بندی و سرعت همگرایی دسته‌بندی دادگان سونار برای الگوریتم EHO و دیگر الگوریتم‌ها.

جدول (۵) مقایسه الگوریتم EHO با دیگر الگوریتم‌ها برای دادگان سونار.

الگوریتم	MSE (Mean)	MSE (Variance)	P-value	نرخ دسته‌بندی
EHO	0.049175	0.0015	1	86.05%
PSO	0.14424	2.8840e-04	4.2557e-86	78.84%
GA	0.083598	0.0058	8.2075e-51	83.65%
ACO	0.1931	7.5069e-04	2.6156e-98	55.76%
ES	0.18935	0.0014	2.4023e-105	59.61%
PBIL	0.12466	0.0021	4.6981e-74	81.73%

۶- نتیجه‌گیری

الگوریتم بهینه‌سازی گروهی فیل‌ها بر آموزش شبکه‌های عصبی چندلایه، مورد استفاده قرار گرفته و نتیجه آن با چندین الگوریتم بهینه‌سازی دیگر مقایسه گشته است. نتایج شبیه‌سازی و نتایج آماری بدست آمده حاکی از آن بوده‌اند که استفاده از عملگر به‌روزرسانی با توجه به نحوه

در این مقاله، یک شبکه‌ی عصبی چندلایه برای اولین بار با استفاده از الگوریتم بهینه‌سازی گروهی فیل‌ها، آموزش داده شد. دادگان گلبرگ، لنز و سونار به ترتیب با ابعاد و پیچیدگی متوسط، کم و زیاد به‌منظور بررسی تاثیر

- Network with Magnified Gradient Function”, IEEE Joint Conference on Neural Networks, Vol.3, pp.1903-1908, 2003.
- [11] Magoulas, G. Vrahatis, M. and Androulakis, G. “On the Alleviation of the Problem of Local Minima in Back-propagation”, Nonlinear Analysis, Theory, Methods & Applications, Vol.30, No.7, pp.4545-4550, 1997.
- [12] Wang, P. Yu, X. and Lu, J. “Identification and Evolution of Structurally Dominant Nodes in Protein-Protein Interaction Networks”, IEEE Transactions on Biomedical Circuits and Systems, Vol.8, No.1, pp.87-97, 2014.
- [13] Gudise, V. G. and Venayagamoorthy, G. K. “Comparison of Particle Swarm Optimization and Back propagation as Training Algorithms for Neural Networks”, IEEE Swarm Intelligence Symposium, pp.110-117, 2003.
- [14] Mendes, R. Cortez, P. Rocha, M. and Neves, J. “Particle Swarms for Feedforward Neural Network Training”, IEEE Joint Conference on Neural Networks, pp.1895-1899, 2002.
- [15] Khishe, M., Mosavi, M. R. and Kaveh, M., “Improved Migration Models of Biogeography-Based Optimization for Sonar Dataset Classification by using Neural Network,” Journal of Applied Acoustics, Vol.118, pp.15-29, 2017.
- [16] Mosavi, M. R., Kaveh, M., and Khishe, M., “Sonar Data Set Classification using MLP Neural Network Trained by Non-linear Migration Rates BBO,” The Fourth Iranian Conference on Engineering Electromagnetics, pp.1-5, 2016.
- [17] Seiffert, U., “Multiple Layer Perceptron Training using Genetic Algorithms”, European Symposium on Artificial Neural Networks, pp.159-164, 2001.
- [18] Blum, C. and Socha, K., “Training Feedforward Neural Networks with Ant Colony Optimization: An Application to Pattern Classification”, Hybrid Intelligent Systems Conference, pp.6-14, 2005.
- [19] Li, G., Na, J., Stoten, D. and Ren, X., “Adaptive Neural Network Feedforward Control for Dynamically Substructured Systems”, IEEE Transactions on Control Systems Technology, Vol.22, No.3, pp.944-954, 2014.
- [20] Simon, D., “Biogeography Based Optimization”, IEEE Transaction on Evolutionary Computation, Vol.12, No.6, pp.702-713, 2008.
- [21] Li, X. and Yin, M., “Multi-Operator based Biogeography-based Optimization with Mutation for Global Numerical Optimization”, Journal of Information Sciences, Vol.64, No.10, pp.2833-2844, 2013.
- [22] Ma, H. and Simon, D., “Analysis of Migration Models of Biogeography-based Optimization using Markov Theory”, Engineering
- به روز کردن وزن‌ها توسط این عملگر و همچنین استفاده از عملگر جدایی، باعث افزایش قدرت بهره‌برداری، تنوع جمعیت در هر نسل و اجتناب از گیر کردن در کمینه‌های محلی شده است. به طوری که الگوریتم پیشنهاد شده دارای نرخ دسته‌بندی بالاتر و سرعت همگرایی بیشتر نسبت به دیگر الگوریتم‌ها می‌باشد. همچنین با ارائه یک ایده پیاده‌سازی برای دسته‌بندی کننده پیشنهادی، نشان داده شده که دیگر مزیت شبکه عصبی، سادگی پیاده‌سازی آن در محیط سخت‌افزار (FPGA) است.

۷- مراجع

- [1] Mosavi, M.R., Khishe, M. and Ebrahimi, E., “Classification of Sonar Targets using OMKC, Genetic Algorithms and Statistical Moments”, Journal of Advances in Computer Research, Vol.7, No.1, pp.50-59, 2015.
- [2] Mosavi, M.R. Khishe, M., Aghababaei, M. and Mohammadzadeh, F., “Approximation of Active Sonar Clutter's Statistical Parameters using Array's Effective Beam-width”, Iranian Journal of Marine Science and Technology, Vol. 73, No.1, pp.11-22, 2015.
- [3] Mirjalili, S., Mirjalili, S. M. and Lewis, A. “Let a Biogeography-based Optimizer Train Your Multi-Layer Perceptron”, Journal of Information Sciences, Vol.269, pp.188-209, 2014.
- [4] Auer, P. Burgsteiner, H. and Maass, W. “A Learning Rule for Very Simple Universal Approximators Consisting of a Single Layer of Perceptrons”, Neural Networks, Vol.21, No.5, pp.786-795, 2008.
- [5] Nguyen, L. S. Frauendorfer, D. Mast, M. S. and Gatica-Perez, D. “Hire Me: Computational Inference of Hirability in Employment Interviews based on Nonverbal Behavior”, IEEE Transactions on Multimedia, Vol.16, No.4, pp.1018-1031, 2014.
- [6] Reed, R. D. and Marks, R. J. “Neural Smithing: Supervised Learning in Feedforward Artificial Neural Networks”, MIT Press, 1998.
- [7] Oja, E. “Unsupervised Learning in Neural Computation”, Theoretical Computer Science, Vol.287, pp.187-207, 2002.
- [8] Zhang, N. “An Online Gradient Method with Momentum for Two-Layer Feedforward Neural Networks”, Applied Mathematics and Computation, Vol.212, pp.488-498, 2009.
- [9] Hush, D. R. and Horne, B. G. “Progress in Supervised Neural Networks”, IEEE Signal Processing Magazine, Vol.10, pp.8-39, 1993.
- [10] Ng, S. C. Cheung, C. C. Leung, S. H. and Luk, A. “Fast Convergence for Backpropagation

-
- Applications of Artificial Intelligence, Vol.24, pp.1052-1060, 2011.
- [23] Farswan, P., Chand, J. and Deep, K., "A Modified Biogeography Based Optimization", *Advances in Intelligent Systems and Computing*, Springer, Vol.22, No.10, pp.662-674, 2016.
- [24] Naseri, M. J., "Floating Buoy Controller Design and Implementation by using Special Sonobuoys", M. S. Thesis, Marine Sciences University of Nowshahr Imam Khomeini, 2015.
- [25] Wang, G., Deb, S. and Coelho, S., "Elephant Herding Optimization", *3rd International Symposium on Computational and Business Intelligence*, pp.6-11, 2015.
- [26] Sukumar, R., "The Asian Elephant: Ecology and Management", Cambridge University Press, New York, 1993.