



الگوریتم مبتنی بر آموزش و یادگیری بهبود یافته

۱ ابراهیم علی زاده ، ۲ علی ملکی، ۳ حمید امیری آرا

۱ دانشگاه صنعتی مالک اشتر، پژوهشکده علوم و فناوری دفاعی شمال، ealizadeh@mut.ac.ir

۲ دانشگاه صنعتی مالک اشتر، پژوهشکده علوم و فناوری دفاعی شمال، ali.maleki86@yahoo.com

۳ دانشگاه صنعتی مالک اشتر، پژوهشکده علوم و فناوری دفاعی شمال، hamid.amiriara@gmail.com

چکیده

در این مقاله یک روش بهینه سازی کارآمد به نام "بهینه ساز مبتنی بر آموزش و یادگیری" جهت یافتن جواب قطعی برای مسائل بهینه سازی، معرفی شده و همچنین الگوریتم بهینه ساز مبتنی بر آموزش و یادگیری بهبود یافته (MTLBO) برای اصلاح این الگوریتم پیشنهاد شده است. الگوریتم TLBO به دو فاز تقسیم بندی می شود، فاز اول، که شامل فراگیری از استاد می باشد و فاز دوم، که شاگردان از تراکنش متقابل همدیگر آموزش می بینند. ما در الگوریتم MTLBO برای جلوگیری از گرفتار شدن الگوریتم در اکستریم های محلی که یک نقطه ضعف برای الگوریتم TLBO است، یک فاز سوم با نام فاز جهش به آن اضافه می نماییم و همچنین تغییراتی در روابط تاثیر معلم بر دانش آموزان ایجاد می نماییم. میزان کارایی روش MTLBO برای بسیاری از توابع محک با خصوصیات متفاوت محاسبه و نتایج با چند روش های جمعیت محور مقایسه گردید. نتایج نشان می دهد که الگوریتم بهبود یافته پیشنهادی بهبود قابل قبولی در کارایی الگوریتم TLBO مرسوم دارد.

واژه های کلیدی: الگوریتم بهینه سازی، دانش آموز، معلم، الگوریتم مبتنی بر آموزش و یادگیری بهبود یافته.

۱- مقدمه

به یافتن مقادیری از پارامترهای تابع هدف که تابع را کمینه یا بیشینه می نماید، بهینه سازی می گویند. کلیه مقادیر مناسب، جواب های ممکن و بهترین مقادیر پارامترها، جواب بهینه تابع نامیده می شود [۱]. الگوریتم های بهینه سازی شامل هر دو مسئله بیشینه سازی و کمینه سازی می باشند. بهینه سازی کاربرد زیادی در مسائل مهندسی مانند تخصیص منابع، تصمیم گیری ها، زمان بندی ها و ... دارد. در روش های سابق، حل مسائل بهینه سازی نیازمند تعداد محاسبات بیشمار بود اما با معرفی الگوریتم های هوش جمعی تا حدی از این محاسبات کاسته شد [۲ و ۳]. هوش جمعی نوعی روش هوش مصنوعی، مبتنی بر رفتارهای جمعی است که در آن اعضای گروه به طور محلی با یکدیگر و با گروه در تعامل هستند و با همکاری یکدیگر راه حل هایی را که تقریباً به جواب نزدیک هستند می یابند [۴ و ۵].

طبیعت مثال کامل و مطلوبی برای بهینه سازی می باشد و بیشتر الگوریتم های تکاملی از طبیعت الهام می گیرند تا مسائل پیچیده را از روش های ساده محاسبه نمایند. هر الگوریتم با ایجاد یک جمعیت اولیه از جواب های مسئله آغاز می گردد و به صورت مکرر از نسلی به نسل دیگر در جهت جواب بهینه حرکت می کند [۶].

الگوریتم مبتنی بر آموزش - یادگیری، یک روش بهینه سازی کارآمد می باشد که برای اولین بار توسط آقای راتو و همکاران معرفی شد [۷]. این روش نیز مشابه سایر تکنیک های بهینه سازی موجود یک الگوریتم برگرفته از طبیعت است و بر اساس تاثیر یک مدرس روی یادگیری کلاس کار می کند. این الگوریتم از یک جمعیتی از جواب ها برای دستیابی به جواب کلی استفاده می نماید.

جمعیت به عنوان گروهی از یادگیران یا دانش آموزان یک کلاس در نظر گرفته می شوند. یک معلم تلاش می کند تا با آموزش به یادگیران، سطح دانش کلاس را افزایش دهد و دانش آموز به نمره یا رتبه خوبی مطابق با توانایی خودش دست یابد. در حقیقت یک معلم خوب کسی است که دانش آموز خود را به سطح دانش خود برساند. معلم یک شخص با دانش بالا در جامعه بوده که علم خود را با دانش آموزان خود تقسیم می کند، به طوری که بهترین جواب (بهترین عضو جمعیت) در همان تکرار به عنوان معلم عمل می کند. اما لازم است به این نکته اشاره شود که شاگردان مطابق با کیفیت آموزش ارائه شده توسط مدرس و وضعیت شاگردان حاضر در کلاس دانش کسب می کنند. به علاوه شاگردان از تراکنش متقابل بین خودشان (بحث گروهی، ارائه ها و ...) که به وضعیتشان کمک می کند آموزش می بینند.

¹ Swarm Intelligence



در الگوریتم TLBO مرسوم با مشکل به دام افتادن الگوریتم در مینیمم محلی مواجه هستیم برای حل این مشکل در این مقاله الگوریتم مبتنی بر آموزش و یادگیری بهبود یافته MTLBO² پیشنهاد می‌نماییم که در آن فاز جدیدی به الگوریتم TLBO به نام فاز جهش را اضافه می‌نماییم. این فاز کمک می‌کند تا بتوان از تله مینیمم محلی فرار کرده و تنوع را در جمعیت حفظ نماییم. بر خلاف الگوریتم TLBO، الگوریتم پیشنهادی MTLBO همه‌سویی³ جمعیت را تضمین می‌نماید. یک جمعیت در صورتی همه‌سو نامیده می‌شود که یک احتمال غیر صفر برای تولید هر راه حل از هر حالت جمعیت وجود داشته باشد.

الگوریتم MTLBO به طور خاص مخصوص مسائل پیوسته می‌باشد ولی با ایجاد تمهیدات خاص می‌توان از آن در مسائل گسسته و باینری نیز استفاده نمود.


در ادامه مقاله به صورت زیر سازماندهی شده است:

- در بخش دوم به صورت کامل به بررسی فلسفه الگوریتم MTLBO می‌پردازیم.
- در بخش سوم، روابط بین معلم با دانش‌آموزان و دانش‌آموزان با یکدیگر را به صورت مدل ریاضی در الگوریتم MTLBO بیان می‌کنیم.
- در بخش چهارم، فلوچارت الگوریتم MTLBO را نمایش داده و بخش‌های مختلف آن را معرفی می‌نماییم.
- در بخش پنجم، الگوریتم MTLBO را با الگوریتم‌های متفاوت دیگر با استفاده از توابع محک گوناگون مقایسه کرده و کارایی این الگوریتم‌ها را با یکدیگر مقایسه می‌نماییم.
- در بخش آخر به نتیجه‌گیری می‌پردازیم.

۲- معرفی الگوریتم MTLBO

این الگوریتم براساس تاثیر یک معلم روی خروجی دانش‌آموزان در یک کلاس می‌باشد و به طور کلی در یک کلاس معلم فردی تعیین می‌شود که دارای مقدار بهتری می‌باشد و سطحی بالاتری نسبت به دانش‌آموزان دارد و می‌تواند دانش‌آموزان را با دانش خود سهیم نماید. یک معلم خوب، یک میانگین بهتر برای دانش‌آموزان تولید می‌نماید. در هر مرحله و تکرار معلم کسی است، که بهترین فرد کلاس باشد و بهترین تابع هدف را دارد. البته در هر مرحله ممکن است معلم تغییر نماید. این الگوریتم جهت استفاده در امور مهندسی گزینه بسیار مناسبی می‌باشد.

در این الگوریتم از فرآیند آموزش و یادگیری که در کلاس درس اتفاق می‌افتد، الهام گرفته شده است. بدین نحو که وقتی معلم درس را ارائه می‌دهد، در نهایت ارزیابی کرده و دانش‌آموزان نیز نمره‌ای را کسب می‌نمایند. اگر نمودار شکل ۱ نمودار توزیع احتمال نمرات افراد باشد، نمودار سمت چپ مربوط به کلاس اول و نمودار سمت راست مربوط به کلاس دوم یا معلم دیگر می‌باشد. با مقایسه سطح نمرات این دو کلاس در می‌یابیم که معلم دوم موفق‌تر عمل کرده است چرا که میانگین سطح کلاس آن که M_2 می‌باشد، از میانگین کلاس اول M_1 بالاتر می‌باشد.



شکل ۱- نمودار توزیع احتمال نمرات دانش‌آموزان

² Modify Teaching Learning Based Optimization

³ Ergodicity



در این نمودار برای نمایش توزیع نمرات از توزیع گوسی استفاده شده است اما می توان از هر توزیع دیگری نیز استفاده نمود. طبق رابطه چگالی احتمال توزیع گوسی میانگین همان M_1 و M_2 می باشد، در این الگوریتم به پراکندگی نمرات یا واریانس پرداخته نمی شود و مهم ترین نکته همان میانگین نمرات دانش آموزان کلاس می باشد.

۳- مدل ریاضی الگوریتم


به طور کلی الگوریتم MTLBO به سه فاز بهینه سازی تقسیم می گردد:

- فاز معلم
- فاز دانش آموز
- فاز جهش

که در ادامه به معرفی این دو بخش می پردازیم.

۳-۱- فاز معلم

در فاز اول، معلم سعی می کند تا میانگین کلاس را به سطح خود برساند و سطح دانش آموزان در این مرحله به سمت معلم تغییر می نماید (شکل ۲). در این الگوریتم معلم از بین دانش آموزان انتخاب می شود، یعنی کسی که اطلاعاتش از بقیه بیشتر باشد و بهتر باشد به عنوان معلم انتخاب خواهد شد.



شکل ۲- نمودار جابجایی در فاز معلم

در نمودار شکل ۲، T_1 به عنوان معلم کلاس انتخاب شده و سعی می کند میانگین سطح کلاس یعنی M_1 را به سطح خودش برساند. اما در واقعیت این امکان پذیر نمی باشد که همه دانش آموزان به سطح معلم برسند بلکه نهایت به سطح میانگین جدید M_2 خواهند رسید. در اینجا به یک جامعه آماری دیگر خواهیم رسید که دارای میانگین M_2 می باشد و معلم جدید، همان بهترین فرد در جمعیت آماری جدید یا T_2 انتخاب خواهد گشت. در این مرحله معلم جدید یا همان T_2 سعی خواهد کرد که میانگین سطح کلاس را به خودش برساند و این روال بدین صورت ادامه خواهد داشت تا جمعیت بهتر شود و به عنوان فاز اول الگوریتم مطرح می شود.

اندازه گام جابجایی برابر است با $(X_{teacher} - Mean)$ که در این رابطه $X_{teacher}$ همان میانگین جدید و مطلوب می باشد و Mean میانگین

فعلی می باشد. بنابراین رابطه ریاضی برای فاز معلم بدین صورت خواهد شد:

$$X_{new} = X_{old} + (X_{teacher} - Mean) \quad (1)$$

این رابطه یک حالت ایده آل می باشد و تنوع جمعیتی ندارد. بنابراین با اضافه کردن دو ضریب تصادفی و یک ضریب وزن خواهیم داشت:

$$X_{new} = X_{old} + W * r(X_{teacher} - T_f Mean) \quad (2)$$

که در آن r یک بردار تصادفی بین صفر و یک بوده که میزان موفقیت یک دانش آموز در درک مطالب یاد داده شده توسط استاد را نشان می دهد. بدین صورت که اگر r برابر صفر باشد یعنی دانش آموز از مطالبی که معلم به او آموزش داده چیزی یاد نگرفته است و اگر r برابر یک باشد یعنی تمام مطالب معلم را فراگرفته است. همچنین T_f یا ضریب معلم نشان دهنده ضریب موفقیت معلم می باشد که $T_f \in \{1, 2\}$ می باشد. اگر ضریب



معلم یک باشد، یک یادگیری معمولی را خواهیم داشت ولی اگر این ضریب ۲ باشد شتاب یادگیری بیشتر خواهد گشت. همچنین در این رابطه W

تابع وزن دهی می باشد و می تواند بصورت رابطه

$$W = W_{Max} - \frac{[(W_{Max} - W_{Min}) \times iter]}{Max_{iter}} \quad (3)$$

تغییر نمایید، که در آن W_{max} وزن اولیه، و W_{min} وزن نهایی است و Max_{iter} تعداد تکرارها (مراحل) و $iter$ تعداد تکرارها تا لحظه کنونی (تا این مرحله) می باشد.

در الگوریتم MTLBO زمانی که W را با رابطه ارائه شده بصورت خطی از یک مقدار نسبتا بزرگ به یک مقدار کوچک کاهش می دهیم، نسبت به الگوریتم TLBO که در آن W مقداری ثابت و برابر یک دارد، عملکرد بهتری خواهیم داشت زیرا دانش آموز در ابتدا بدون توجه به معلم به جستجوی سراسری پرداخته و با گذشت چند دوره حضور در کلاس به جستجوی محلی و یادگیری از معلم می پردازد. در حالتی که W بزرگتر است، توانایی جستجوی سراسری بیشتر و در حالت W کوچکتر، توانایی جستجو محلی بیشتر است.

۳-۲- فاز دانش آموز

فاز دانش آموز بعد از فاز معلم اجرا می شود و دانش آموزان می توانند از یکدیگر نیز آموزش ببینند و بر روی یکدیگر تاثیر بگذارند و این تعامل باعث می شود که سطوح دانش آموزان ارتقا پیدا نماید. این فاز که نام دیگر آن فاز یادگیری می باشد همان طور که در شکل ۳ مشخص می باشد دانش آموزان با تعامل و بحث و گفتگو با یکدیگر سعی در افزایش سطح دانش هم دارند.

با توجه به شکل ۳ دو دانش آموز تصادفی از بین جمعیت انتخاب خواهد شد که در آن دانش آموز اول یعنی x_i می خواهد از دانش آموز دوم

یعنی x_j آموزش ببیند، بسته به میزان نمره این دو دانش آموز دو حالت برای اثر پذیری دانش آموز x_i از دانش آموز x_j به وجود خواهد آمد:

- حالت اول: اگر نمرات دانش آموز در حال یادگیری از دانش آموز آموزش دهنده بدتر باشد.
- حالت دوم: اگر نمرات دانش آموز در حال یادگیری از آموزش دهنده بهتر باشد.

حالت اول: اگر نمرات دانش آموز در حال یادگیری از دانش آموز آموزش دهنده بدتر باشد.

در این حالت یک دانش آموز ضعیف (x_i) می خواهد از یک دانش آموز با نمرات بهتر آموزش (x_j) ببیند در نتیجه بهترین حالت این است که سطح دانش آموز x_i دقیقا برابر x_j گردد، که در این صورت رابطه ریاضی برای این حالت عبارت خواهد بود با $x_i^{new} = x_j$ یا:

$$x_i^{new} = x_i + (x_j - x_i) \quad (4)$$

مشابه فاز معلم برای افزایش تنوع جمعیتی به این رابطه ایده آل یک ضریب تصادفی اضافه می نماییم:

$$x_i^{new} = x_i + r(x_j - x_i) \quad (5)$$

که در این رابطه r یک بردار تصادفی بین صفر و یک بوده که میزان موفقیت دانش آموز x_i در درک مطالب یاد داده شده توسط دانش آموز x_j را نشان می دهد.


حالت دوم: اگر نمرات دانش آموز در حال یادگیری از آموزش دهنده بهتر باشد

همان طور که در شکل ۳ مشخص می باشد در این حالت دانش آموز در حال یادگیری که همان x_i می باشد از دانش آموز در حال آموزش یعنی x_j دارای نمرات بهتری می باشد. بدین منظور برای بهبود موقعیت x_i باید تا جای ممکن از x_j فاصله بگیرد. بنابراین به اندازه طول گام یعنی

$(x_i - x_j)$ از آن فاصله می گیرد و رابطه ریاضی برای این حالت به صورت زیر خواهد بود:

$$x_i^{new} = x_i + r(x_i - x_j) \quad (6)$$

که در این رابطه نیز r یک بردار تصادفی بین صفر و یک می باشد.



شکل ۳- حالت اول: اگر نمرات آموزش گیرنده از آموزش دهنده بدتر باشد. حالت دوم: اگر نمرات آموزش گیرنده از آموزش دهنده بهتر باشد.

باید به این نکته اشاره کرد که در هر دو فاز معلم و دانش آموز با بدست آمدن دانش آموز جدید (x) مقدار تابع هدف محاسبه می شود و اگر این مقدار از مقدار تابع هدف دانش آموز قدیم بهتر باشد، دانش آموز جدید جایگزین دانش آموز قدیم می شود در غیر این صورت دانش آموز قدیم بدون تغییر می ماند.

۳-۳- فاز جهش

در هر تکرار یک بردار جهش با دانش آموزان اصلاح شده به صورت رابطه

$$x_i^{mut} = x_{rand1} + r(x_{rand2} - x_{rand3}) \quad (7)$$

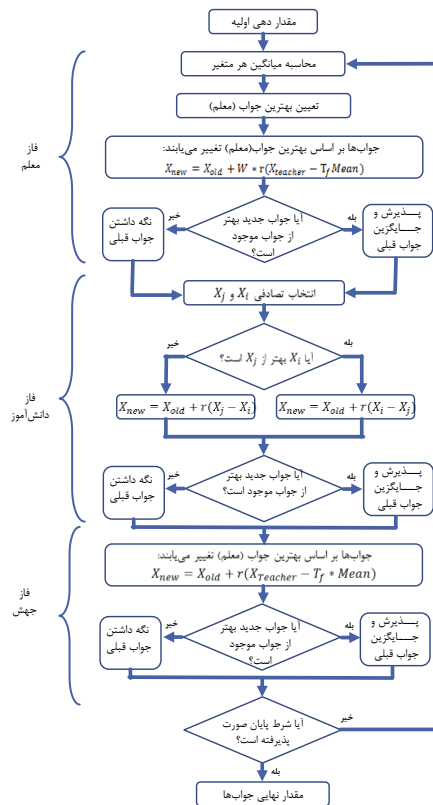
تولید می شود، که در آن x_{rand1} ، x_{rand2} و x_{rand3} سه دانش آموز تصادفی غیر هم شکل و r (ضریب مقیاس بندی جهش) یک عدد تصادفی در بازه $[0,1]$ است. در نهایت عضو جهش یافته x_i^{mut} در صورتی که بهتر از x_i^{new} باشد، پذیرفته خواهد شد.

۴- فلوجارت الگوریتم MTLBO

الگوریتم MTLBO روندی مشابه سایر الگوریتم های بهینه سازی دارد که شامل پنج بخش اصلی می باشد. که به ترتیب به قرار زیر می باشند:

- تعریف مسئله
- پارامترهای الگوریتم
- آماده سازی
- حلقه اصلی (شامل فاز معلم، فاز دانش آموز و فاز جهش)
- نتایج

این بخش ها به ترتیب در فلوجارت الگوریتم در شکل ۴ نمایش داده شده است.



شکل ۴- فلوجارت الگوریتم MTLBO

۵- نتایج شبیه سازی و مقایسه عملکرد

در این بخش، توانایی الگوریتم MTLBO با اجرا آن برای بهینه سازی تعدادی از توابع محک با بعدها و فضای جستجوی متفاوت مورد ارزیابی می گردد. نتایج حاصل از الگوریتم MTLBO با الگوریتم TLBO و مابقی الگوریتم های بهینه ساز موجود در مقالات مقایسه می گردد. تابع محک های در نظر گرفته شده دارای خواص متفاوتی مانند بدون قید و چند قیده، تفکیک پذیر و عدم تفکیک پذیر و با قاعده و بدون قاعده می باشند.

۵-۱- آزمایش اول

برای تعیین پیچیدگی محاسباتی و ثبات الگوریتم TLBO، هشت تابع محک متفاوت در این بخش مورد امتحان قرار گرفته است. نتایج حاصل از به کارگیری الگوریتم MTLBO پیشنهادی با الگوریتم های بهینه ساز شناخته شده دیگر مقایسه گردید. جزئیات تابع محک ها در پیوست الف آورده شده است. برای هماهنگی میان تمامی الگوریتم های مقایسه شده، زمانی که اختلاف میان مقدار تابع شایستگی بدست آمده از الگوریتم و مقدار نقطه بهینه مطلق کمتر از ۰.۰۱٪ گردید، الگوریتم متوقف می شود برای مثال اگر نقطه بهینه صفر باشد، آن جوابی مورد قبول می گردد که از نقطه بهینه به اندازه کمتر از ۰.۰۰۱ اختلاف داشته باشد. هر یک از توابع محک به تعداد ۱۰۰ بار با الگوریتم MTLBO محاسبه گردید و میانگین تعداد ارزیابی تابع و درصد موفقیت در جدول ۱ نمایش داده شده است.

۵-۲- آزمایش دوم

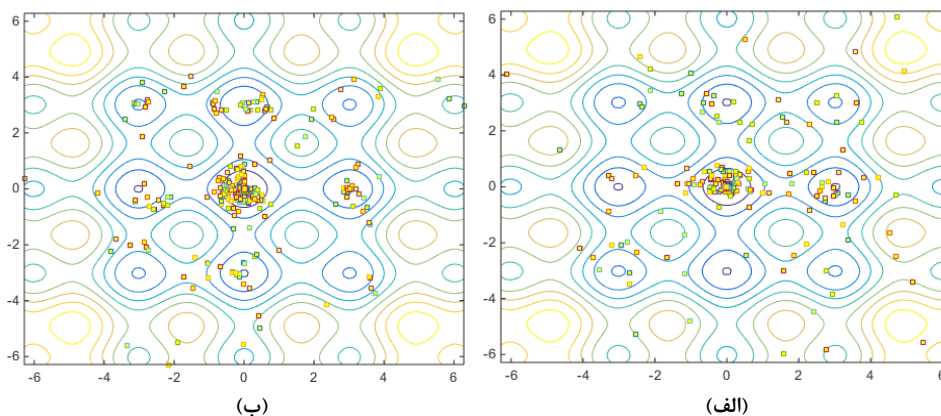


جدول ۱- نتایج حاصل از به کارگیری الگوریتم MTLBO با الگوریتم های بهینه ساز شناخته شده دیگر

	De Jong		Goldstein and Price		Branin		Martin and Gaddy	
	MNFE	Succ %	MNFE	Succ %	MNFE	Succ %	MNFE	Succ %
GA	10 160	100	5662	100	7325	100	2488	100
ANTS	6 000	100	5330	100	1936	100	1688	100
Bee Colony	868	100	999	100	1657	100	526	100
GEM	746	100	701	100	689	100	258	100
TLBO	1 070	100	452	100	443	100	422	100
Improve TLBO	862	100	439	100	435	100	357	100

	Rosenbrock (D = 2)		Rosenbrock (D = 2)		Rosenbrock (D = 4)		Hyper sphere (D = 6)	
	MNFE	Succ %	MNFE	Succ %	MNFE	Succ %	MNFE	Succ %
GA	10 212	100	-	-	-	-	15 468	100
ANTS	6 842	100	7 505	100	8 471	100	22 050	100
Bee Colony	631	100	2 306	100	28 529	100	7 113	100
GEM	572	100	2 289	100	82 188	100	423	100
TLBO	669	100	1 986	100	21 426	100	417	100
Improve TLBO	550	100	1892	100	18 692	100	396	100

برای تعیین میزان توانایی جستجوی الگوریتم MTLBO و تعیین نقطه بهینه قطعی از میان تعداد زیادی از نقاط بهینه محلی، تابع محک جعبه تخم مرغ که در پیوست ب معرفی شده است، در نظر می گیریم. در شکل ۵ (الف) و (ب) به ترتیب نقاط تعیین شده از هر دوره الگوریتم های TLBO و MTLBO بر روی نمودار کانتور این تابع محک رسم شده است. همانطور که از مقایسه این دو شکل مشخص است، الگوریتم MTLBO تقریباً تمامی نقاط بهینه محلی را مورد بررسی قرار داده است. این بدین معنی است که قابلیت جستجوی این الگوریتم نسبت به الگوریتم TLBO بیشتر شده و احتمال تعیین نقطه مینیمم محلی به جای دستیابی به نقطه بهینه قطعی کاهش می یابد.



شکل ۵- الف: نقاط تعیین شده از هر دوره الگوریتم TLBO ب: نقاط تعیین شده از هر دوره الگوریتم MTLBO

۶- نتیجه گیری

یک روش بهبود یافته برپایه الگوریتم بهینه سازی، TLBO که بر پایه فلسفه مراحل آموزش- یادگیری ارائه گردید و کارایی آن به وسیله آزمایشات با مسائل محک گوناگون با خصوصیات متفاوت بررسی گردید. بر خلاف الگوریتم TLBO، الگوریتم MTLBO پیشنهادی همسویی^۶ جمعیت را تضمین می نماید و از به دام افتادن الگوریتم در مینیمم محلی جلوگیری می نماید. کارایی الگوریتم MTLBO همچنان برای ملاک های متعدد

⁶ Egg Create

⁷ Contour

⁸ Ergodicity



مانند میانگین تعداد ارزیابی تابع هدف و میزان جستجو مورد آزمایش قرار گرفت. نتایج کارایی بهتر MTLBO را در مقابل روش TLBO و روش های بهینه سازی دیگر برای تابع معیار ثابت نشان می دهد.

۷- مراجع

- [1] J.F. Goncalves, J.J.M. Mendes, M.G.C. Resende, A genetic algorithm for the resource constrained multi-project scheduling problem, European Journal of Operational Research 189 (2008) 1171–1190.
- [2] Z. Wu, G. Ding, K. Wang, M. Fukaya, Application of a genetic algorithm to optimize the refrigerant circuit of fin-and tube heat exchangers for maximum heat transfer or shortest tube, International Journal of Thermal Science 47 (2008) 985–997.
- [3] S. Suresh, P.B. Sujit, A.K. Rao, Particle swarm optimization approach for multi objective composite-beam design, Composite Structure 81 (2007) 598–605.
- [4] R.E. Perez, K. Behdinan, Particle swarm approach for structural design optimization, Computers and Structures 85 (2007) 1579–1588.
- [5] Shilane. D, Martikainen. J. S and Dudoit. S, A general frame-work for statistical performance comparison of evolutionary computation algorithms, Information Sciences, Journal, 178, 2870-2879, 2008.
- [6] Vallada. E and Ruiz. R, Genetic algorithms with path re linking for the minimum tardiness permutation flowshop problem, Omega, 38, 57 -67, 2011.
- [7] Rao RV, Savsani VJ, Vakharia DP. "Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems," Comput-Aided Design 2011; 43:303–15.
- [8] Ahrari, A. and Atai, A.A. "Grenade explosion method a novel tool for optimization of multimodal functions", Appl. Soft Comput 2010, 10, pp. 1132–1140.

پیوست الف: معرفی توابع محک

تعدادی از توابع محک معروف که در مقالات از آن ها برای ارزیابی الگوریتم های بهینه ساز استفاده می گردد در جدول ۲ گردآوری شده است. منظور از ستون ابعاد در این جدول بعد جواب های مسئله می باشد و در ستون محدوده جستجو محدوده فضای جستجو فرض شده در آزمایشات این مقاله می باشد.

جدول ۲- معرفی توابع محک [۸]

تابع معیار	فرمول	ابعاد	محدوده جستجو
۱ De Jong	$Fmin = 3905.93 - 100(x_1^2 - x_2)^2 - (1 - x_1)^2$	۲	$[-۲, ۰۴۸, ۲, ۰۴۸]$
۲ GoldStein-Price	$Fmin = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] [30 + (2x_1 - 3x_2)^2(18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	۲	$[-۲, ۲]$
۳ Branin	$Fmin = (x_2 - \frac{5.1}{4\pi^2}x_1^2 + \frac{5}{\pi}x_1 - 6)^2 + 10(1 - \frac{1}{8\pi})\cos x_1 + 10$	۲	$[-۵, ۱۰]$
۴ Martin and Gaddy	$Fmin = (x_1 - x_2)^2 + [\frac{x_1 + x_2 - 10}{3}]^2$	۲	$[۰, ۱۰]$
۵ Rosenbrock	$Fmin = 100(x_1^2 - x_2)^2 + (1 - x_1)^2$	۲	$[-۱, ۲, ۱, ۲]$
۶ Rosenbrock	$Fmin = 100(x_1^2 - x_2)^2 + (1 - x_1)^2$	۲	$[-۱۰, ۱۰]$
۷ Rosenbrock	$Fmin = \sum_{i=1}^D 100(x_i^2 - x_{i+1})^2 + (1 - x_i)^2$	۳	$[-۱۰, ۱۰]$
۸ Hyper Sphere	$Fmin = \sum_{i=1}^D x_i^2$	۶	$[-۵, ۱۲, ۵, ۱۲]$

پیوست ب: تابع محک جعبه تخم مرغ

تابع محک جعبه تخم مرغ در این بخش معرفی می گردد. رابطه این تابع محک به صورت

$$Fmin = x_1^2 + x_2^2 + (25 * (\sin(x_1)^2 + \sin(x_2)^2)) \quad (۸)$$

می باشد. از آنجایی که این تابع محک دارای نقاط اکسترمم های محلی زیادی است، معمولاً از این تابع محک برای آزمایش عدم انتخاب نقطه بهینه محلی بجای نقطه بهینه قطعی یا همان قدرت جستجوی الگوریتم استفاده می گردد.



Modified Teaching Learning Based Optimization

Ebrahim Alizadeh, Ali Maleki, Hamid Amiriara

Shomal instiute of defense scinece and technology, University of Malek-Ashtar, E-mail: ealizadeh@mut.ac.ir
Shomal instiute of defense scinece and technology, University of Malek-Ashtar, E-mail: ali.maleki86@ yahoo.com
Shomal instiute of defense scinece and technology, University of Malek-Ashtar, E-mail: hamid.amiriara@gmail.com

Abstract. In this paper teaching- learning based optimizer (TLBO) as effective optimization method for finding exact response for optimization problems is introduced also MTLBO is proposed to modify this algorithm. TLBO is divided to two phases: first phased include training from teacher and in second phase, students learn to each other. In MTLBO, we added third phase to TLBO to prevent local extreme and also change the effect of teacher on students. The accuracy of MTLBO for mast of benchmarks function is calculated and the results are compared to some other algorithms. The results show that the proposed algorithm has more accuracy with respect to TLBO.

Keywords: optimization algorithm, student, teacher, teaching- learning based optimization.