

الگوریتم یادگیری بهینه سازی جستجوی عقبگرد و کاربردهای آن

چکیده

الگوریتم جستجوی عقبگرد (BSA) پیشنهادی در این مقاله، یک الگوریتم تکاملی (EA) می باشد که برای حل مسائل بهینه سازی استفاده می شود. ساختار این الگوریتم ساده می باشد و تنها دارای یک پارامتر کنترلی است که باید تعیین شود. به منظور بهبود عملکرد همگرایی و گسترش دامنه استفاده از آن، یک الگوریتم جدید به نام یادگیری BSA (LBSA) در این مقاله ارائه شده است. در این روش، بطور سراسری از بهترین اطلاعات نسل حاضر و اطلاعات پیشین در BSA، برای گزینش مجدد افراد باتوجه به احتمال تصادفی ترکیب می شوند و افراد باقی مانده موقعیت خود را توسط یادگیری دانش در بهترین فرد، بدترین فرد و یک فرد تصادفی از نسل حاضر دوباره انتخاب می کنند. دو مزیت مهم برای این الگوریتم وجود دارد. 1) بعضی از افراد موقعیت خود را با هدایت بهترین فرد (آموزش دهنده) بروزرسانی می کنند، که باعث همگرایی سریعتر می شود، 2) یادگیری از افراد متفاوت، بطور ویژه زمانی که بدترین فرد نادیده گرفته می شود، تنوع جمعیت را افزایش می دهد. برای آزمایش بهترین عملکرد LBSA، توابع سنجشی در CEC2005 و CEC2014 مورد آزمایش قرار گرفتند و این الگوریتم به منظور آموزش شبکه های عصبی برای پیش بینی سری های زمانی بی نظم و مشکلات مدل سازی سیستم های غیرخطی استفاده می شود. برای ارزیابی عملکرد BSA با بعضی از EAهای دیگر، چند مقایسه بین LBSA و دیگر الگوریتم های کلاسیک انجام شده است. نتایج نشان می دهند که LBSA با توجه به الگوریتم های دیگر عملکرد خوبی دارد و باعث بهبود عملکرد الگوریتم BSA می شود.

کلید واژه ها: الگوریتم تکاملی. الگوریتم جستجوی عقبگرد. بهینه سازی مبتنی بر آموزش-یادگیری. آموزش شبکه

1. مقدمه

برخی از مشکلات علوم و مهندسی حل مسائل بهینه سازی می باشد، که امروزه محققان در تلاش برای جستجو و طراحی الگوریتم های بهینه سازی بهتر می باشند. برای حل مسائل پیچیده مانند توابع غیرخطی، مشتق ناپذیر و تابع هدف غیر- محدب، محققان بر طراحی الگوریتم های تکاملی (EA) جدید یا بهبود عملکرد الگوریتم های موجود متمرکز شده اند. از این الگوریتم ها، الگوریتم بهینه سازی هوش جمعی و الگوریتم های تکامل ژنتیکی در حل مسائل پیچیده بهینه سازی نقش بسیار مهمی دارند. الگوریتم بهینه سازی ازدحام ذرات (PSO) [12]، که به تقلید از جستجوی پرندگان می باشد، در استفاده برای بهینه سازی توابع [37]، مسائل طبقه بندی شده ترتیبی [36] و سیستم های تولید برق [25] عملکرد خوبی دارد. برخی از انواع روش های PSO، مانند روش ازدحام ذرات کاملاً آگاه (PSOFIPS) [20]، PSO مبتنی بر نسبت فاصله برازش (PSOFDR) [23] و یادگیری جامع ازدحام ذرات (CLPSO) [15]، می باشند که برای بهبود عملکرد الگوریتم PSO و حل مسائل بهینه سازی پیشنهاد شده اند. علاوه بر این، برخی از الگوریتم های ترکیبی نیز برای بهبود عملکرد الگوریتم PSO [13,21] معرفی شده اند و همچنین برخی روش های گسسته برای گسترش دامنه کاربرد الگوریتم PSO [2,8,10] پیشنهاد شده است. شبیه سازی فرآیند آموزش-یادگیری در الگوریتم بهینه سازی مبتنی بر یادگیری-آموزش (TLBO) [31] نیز ارائه شده است. در این روش پارامترهای کمتری وجود دارند که باید در معادلات بروزرسانی تعیین شوند، که این کار باعث می شود الگوریتم به آسانی اجرا شود. برای استفاده کامل از مزایای الگوریتم TLBO، دو روش در نظر گرفته شده است: یکی از این روش ها بهبود کارایی الگوریتم توسط تغییر فرآیند بروزرسانی یا ترکیب آن با دیگر EAها و از سوی دیگر گسترش دامنه های کاربردی آن است. طرح نخبه گرایی که در الگوریتم نخبه گرایی (ETLBO) TLBO استفاده شده است برای بهبود عملکرد خود برخی از بدترین یادگیرنده ها را در گروه هایی توسط نخبه های دیگر جایگزین می کند [29]. یک TLBO خود یادگیر که یک روش خود یادگیری جدید می باشد برای آموزش

مدلسازی عصبی تابع پایه شعاعی (RBF) باتری ها استفاده شده است [41]. بسیاری از آموزش دهندها، از عامل آموزش تطبیقی، خودآموز آموزشی و یادگیری خود انگیزی برای بهبود تنوع جمعیت استفاده می کنند [30]. الگوریتم اصلاح شده TLBO عملکرد خوبی برای انجام برخی از مسائل بهینه سازی داشته است. با توجه به زمینه های کاربردی، عملگر جهش لوی (Levy) [7] برای کمک به جلوگیری از بوجود آمدن نقطه بهینه محلی TLBO استفاده شده است و الگوریتم جدید با موفقیت برای سیستم IEEE سی شینه استفاده شده است. TLBO بهبود یافته [6] در جهتی یکسو برای افزایش توانایی جستجوی آموزش دهنده ها معرفی شده است که با یک الگوریتم تکاملی تفاضلی دوطرفه برای کنترل مسئله پخش بار بهینه توان راکتیو (ORPD) ترکیب شده است. روش های محلی و خود یادگیر [3] به منظور بهبود عملکرد TLBO ابتکاری استفاده شده است، این روش ها عملکرد خوبی از خود برای مسائل بهینه سازی سراسری نشان می دهند. بهینه سازی مبتنی بر آموزش-یادگیری چند هدفه [19] برای کنترل توان راکتیو سیستم ها استفاده می شود. بهینه سازی مبدل های حرارتی صفحه ای-پره دار [22] و فرآیندهای ماشینکاری مدرن [28]، مشکلات بهینه سازی برنامه ریزی واحدهای حرارتی آبی بلند مدت [32]، بهینه سازی سرد کن های حرارتی دو مرحله ای [27] و مشکلات برنامه ریزی دوباره خط تولید [11,14] توسط الگوریتم بهینه سازی TLBO حل شده اند. بررسی دقیق برنامه های کاربردی TBLO را می توان در مقاله [26] یافت. ساده سازی فرآیند آموزش و کاهش تعداد پارامترهای نامعین الگوریتم های بهینه سازی هوشمند موضوع بسیار مهمی می باشد. برای پرداختن به این موارد، یک الگوریتم جدید به نام الگوریتم جستجوی عقبگرد (BSA) [5] در سال 2013 پیشنهاد شده است که برای برخی از مشکلات بهینه سازی مهندسی استفاده می شود. الگوریتم BSA برای تجزیه و تحلیل موج سطحی [34] و برای حل مسائل بهینه سازی ترکیب آرایه های آنتن مدور متحدالمرکز استفاده می شود [9]. BSA و الگوریتم تکامل تفاضلی (DE) را می توان برای حل مسائل بهینه سازی بدون محدودیت باهم ترکیب نمود [40]. الگوریتم BSA مقابله ای [17] برای حل مسائل بهینه سازی، شناسایی پارامتر سیستم های فوق آشوبی معرفی شده است. الگوریتم BSA با سه روش کنترل محدودیت [43] برای حل مسائل بهینه سازی که دارای محدودیت می باشند استفاده می شود. برای برخی از EA های کلاسیک، BSA الگوریتم

بهینه سازی بسیار جدیدی می باشد و از طرفی نوع بهبود یافته الگوریتم BSA به نسبت کم تر مورد تحلیل قرار گرفته است.

همانطور که در بالا ذکر شده است، BSA و TLBO هر دو نشان دادند که در حل برخی از مسائل بهینه سازی بهتر از الگوریتم های دیگر می باشند، بویژه به دلیل آنکه الگوریتم ها ساده هستند و پارامترهای نامعین کمی در معادلات روزرسانی فردی وجود دارد. از طرفی عملکرد الگوریتم های نوین در حل مسائل پیچیده نیاز به بهبود دارد. معایب این الگوریتم ها در بخش های 2 و 3 بصورت دقیق تر آمده است.

برای بهبود عملکرد سراسری الگوریتم BSA، یک روش جدید که ترکیبی از ایده های TLBO و BSA می باشد در این مقاله ارائه شده است. بخش اصلی روش جدید به شرح زیر می باشد. بخش اول علاوه بر هدایت یادگیری در معادلات روزرسانی BSA سرعت همگرایی BSA را بهبود می بخشد. بخش دوم برای ادغام سه روش یادگیری در یک معادله به منظور روزرسانی افراد باتوجه به احتمالات تصادفی است. یکی دیگر از بخش ها اجتناب از استفاده بدترین فرد در جهت بهبود تنوع یا گوناگونی جمعیت می باشد. در مقابل برای دو تابع ارزیابی (FE) برای یک فرد در یک نسل از الگوریتم TLBO، تنها یک FE در هر نسل برای روش جدید وجود دارد. از این رو، هزینه محاسبات برای یک نسل از الگوریتم پیشنهادی نسبت به TLBO کمتر است.

بقیه مقاله به شرح زیر می باشد: BSA بنیادی و TLBO ابتکاری بطور مختصری به ترتیب در بخش 2 و بخش 3 معرفی شده اند؛ LBSA در بخش 4 ارائه شده است؛ توابع سنجشی در CEC2005 و CEC2014 برای نشان دادن اثر الگوریتم های مختلف در بخش 5 آزمایش شده اند؛ برنامه های کاربردی برای دو مشکل مدلسازی غیرخطی و مشکلات پیش بینی سری های زمانی آشوبی در بخش 6 نمایش داده شده است و در نهایت نتیجه گیری در بخش 7 آمده است.

2. BSA بنیادی

BSA یک EA مبتنی بر جمعیت است که با استفاده از الگوریتم DE توسعه یافته است، اما شبیه به الگوریتم DE

نمی باشد. این الگوریتم شامل 5 فرآیند می باشد: مقدار دهی اولیه، گزینش-1، جهش، ترکیب و گزینش-2. دو تنوع جمعیتی در BSA وجود دارد: یک از آنها جمعیت تکاملی و دیگری جمعیت آزمایشی می باشد. جمعیت آزمایشی از برخی اطلاعات پیشین جمعیت تکاملی تشکیل شده است و یک ماتریس جستجوی جهت دار توسط دو جمعیت برای بروزرسانی موقعیت افراد ایجاد می شود. تنها یک پارامتر کنترل، یعنی نرخ ترکیبی وجود دارد، که تعداد عناصر فردی را کنترل می کند و در یک آزمایش جهش می یابد. پنج مرحله از BSA به شرح زیر می باشد و جزئیات بیشتر آن در مقاله [5] بیان شده است.

(1) مقداردهی اولیه. جمعیت اولیه و تاریخچه جمعیت BSA با توجه به معادله 1 و 2 مقدار دهی می شوند، که U توزیع یکنواخت می باشد و z پایین و z بالا مرزهای پایین و بالای متغیرها هستند.

$$P_{i,j} \sim U(low_j, up_j) \quad (1)$$

$$oldP_{i,j} \sim U(low_j, up_j) \quad (2)$$

که i فرد i ام جمعیت است و $N, \dots, 2, 1$ ، $i=1, 2, \dots, N$ که مقدار جمعیت می باشد، z بیت z ام از فرد i ام است، $z=1, \dots, D$ که D اندازه ابعاد متغیرها می باشد.

(2) گزینش-1: در شروع هر تکرار، تاریخچه جمعیت $oldP$ در BSA با توجه به رابطه 3 و 4 معرفی می شود:

$$oldP = \begin{cases} P & \text{if } (a < b | a, b \sim U(0, 1)) \\ oldP & \text{otherwise} \end{cases} \quad (3)$$

$$oldP := \text{permuting}(oldP) \quad (4)$$

(3) جهش. فرم اولیه جمعیت آزمایشی BSA توسط عملیات جهش با توجه به معادله (5) تولید می شود. همانطور که در معادله (5) نشان داده شده است، BSA با استفاده از مزیت تجربیات خود از نسل های قبلی به تولید یک جمعیت آزمایشی می پردازد؛ اطلاعات پیشین جمعیت، کل فرآیند تکاملی را در برمی گیرد. F دامنه ماتریس جستجوی جهت دار را کنترل می کند. مقدار مشترک F برابر با $3 \cdot randn$ است که در آن $randn \sim N(0, 1)$ می باشد.

$$M = P + F \cdot (oldP - P) \quad (5)$$

(4) ترکیب . در BSA ، مقدار اولیه جمعیت آزمایشی از فرآیند جهش بوجود می آید و افراد آزمایشی با برآزش بهتر برای تکامل افراد جامعه هدف استفاده می شوند. یک ماتریس با داده های مقداری صحیح باینری (نگاشت) با اندازه $N \cdot D$ ، مسیرهای ترکیب شده الگوریتم BSA را هدایت می کند. استراتژی ترکیب BSA در رابطه 6 بیان شده است.

$$V_{i,j} = \begin{cases} P_{i,j} & \text{if } map_{i,j} = 1 \\ M_{i,j} & \text{otherwise} \end{cases} \quad (6)$$

گزینش-2 . در این مرحله، جمعیت نسل بعدی باتوجه به مکانیزم گزینش حریصانه تولید می شود. در روش پیشنهادی، برای مسائل کوچک، اگر برآزش V_i نسبت به p_i کوچکتر باشد، p_i جایگزین V_i می شود. این فرآیند در رابطه 7 نشان داده شده است.

$$p_i^{next} = \begin{cases} V_i & \text{if } f(V_i) \leq f(P_i) \\ P_i & \text{otherwise} \end{cases} \quad (7)$$

همانطور که در مقدمه ذکر شد، BSA الگوریتمی با ساختار ساده تر نسبت به برخی از EA ها، مانند PSO ها، الگوریتم ژنتیک و DE ها می باشد. ترکیب و مکانیزم جهش از الگوریتم DE و انواع آن متفاوت می باشند. اطلاعات پیشین در فرآیند بروز رسانی برای بهبود عملکرد الگوریتم استفاده می شوند. با این حال، به عنوان یک الگوریتم نوین، BSA نیز معایبی دارد. اولین عیب آن نبودن هیچ هدایت کننده ای به عنوان بهترین فرد در فرآیند بروز رسانی می باشد که می تواند باعث سرعت همگرایی آهسته BSA شود. دومین عیب BSA، زمانی می باشد که تنوع جمعیت از بین رفته و افراد نمی توانند دوباره انتخاب شوند، زیرا جمعیت آزمایشی هنگامی که جمعیت تقریباً شبیه به نسل بعدی است ممکن نیست تغییر کند. این امر باعث کاهش توانایی BSA برای جلوگیری از ایجاد نقطه بهینه محلی می شود.

3. مراحل اصلی TLBO

TLBO نیز مانند EA مبتنی بر جمعیت می باشد که فلسفه آموزش و یادگیری در یک گروه را تقلید می کند. دو مرحله اصلی در TLBO وجود دارد: که مرحله آموزش دهنده و مرحله یادگیرنده می باشند. از آنجا که تنها ایده

های یادگیری در الگوریتم پیشنهادی یادگیری BSA (LBSA) استفاده می شود، تنها دو مرحله اصلی الگوریتم TLBO در این بخش شرح داده شده است.

3.1 مرحله آموزش دهنده

در مرحله آموزش دهنده، آموزش دهنده دانش خود برای همه ی یادگیرنده ها در گروه توزیع می کند و یادگیرنده ها موقعیت خود را با توجه به آموزش دهنده و موقعیت میانگین گروه حاضر بروز رسانی می کنند. یادگیرنده با بهترین برازش برای آموزش دهنده شدن انتخاب می شود. برای یک مسئله بهینه سازی با ابعاد D ، فرض کنید موقعیت یادگیرنده i ام $X_i = \{X_{i,1}, X_{i,2}, \dots, X_{i,D}\}$ باشد، که در آن X_{mean} نشان دهنده راه حل میانگین گروه حاضر است و $X_{teacher}$ نشان دهنده موقعیت آموزش دهنده می باشد. یادگیرنده i ام موقعیت خود را با توجه به تفاوت بین آموزش دهنده و موقعیت میانگین بروز رسانی می شود که به شرح زیر می باشد:

$$X_{new,i} = X_{old,i} + rand(.) * (X_{teacher} - T_F X_{mean}) \quad (8)$$

که $X_{old,i}$ و $X_{new,i}$ به ترتیب موقعیت های جدید و پیشین یادگیرنده i ام می باشند و $rand(\bullet)$ عددی تصادفی در محدوده $[0, 1]$ می باشد. مکانیزم انتخاب حریصانه برای پذیرش بهتر $X_{new,i}$ و $X_{old,i}$ استفاده می شود. پس از آنکه موقعیت پذیرفته شود به مرحله یادگیرنده انتقال می یابد. ضریب آموزش T_F ، مقدار میانگین را برای تغییر داده شدن تعیین می کند. مقدار T_F بصورت ابتکاری بر روی 1 یا 2 تنظیم می شود. این تصمیم تصادفی با احتمال برابر به شرح زیر می باشد:

$$T_F = round[1 + rand(0, 1)\{2 - 1\}] \quad (9)$$

3.2 مرحله یادگیرنده

در هر تکرار، یادگیرنده k ام بصورت تصادفی به عنوان هدف یادگیری، یادگیرنده i ام انتخاب می شود. روش یادگیری، یادگیرنده i ام می تواند بصورت ریاضی به شرح زیر بیان شود:

$$X_{new,i} = \begin{cases} X_{old,i} + rand(.) (X_{old,i} - X_{old,k}) & \text{if } f(X_{old,i}) < f(X_{old,k}) \\ X_{old,i} + rand(.) (X_{old,k} - X_{old,i}) & \text{otherwise} \end{cases} \quad (10)$$

که $X_{new,i}$ ، موقعیت جدید فرد i ام است و $X_{old,i}$ و $X_{old,k}$ ، به ترتیب موقعیت های پیشین i ام و k ام یادگیرنده ها هستند. علاوه بر این، اگر برآزش $X_{new,i}$ نسبت به $X_{old,i}$ بهتر باشد $X_{new,i}$ پذیرفته می شود. ساختار TLBO ساده می باشد و از طرفی پارامترهایی که باید در معادلات بروز رسانی از پیش تعیین شده باشند در این الگوریتم وجود ندارد. به همین دلیل از این الگوریتم بطور گسترده برای حل مسائل بهینه سازی که داری قطعیت می باشند استفاده می شود. با این حال، این الگوریتم نیز دارای دو عیب می باشد. عیب اول آن است که دو F_E برای هر فرد در هر نسل وجود دارد و از این رو هزینه محاسبه یک نسل نسبت به الگوریتمی با یک F_E برای هر فرد در هر نسل بزرگتر است. عیب دوم آن است که دانش یادگیری از بهترین یادگیرنده ها و دو گزینش حریصانه از یک فرد ممکن است تنوع جمعیت را به سرعت کاهش دهد. به منظور بهبود عملکرد BSA، مکانیزمی برای یادگیری TLBO و یک عملگر مقابله کننده برای بهبود تنوع جمعیت در این مقاله پیشنهاد شده است. علاوه بر این، تنها یک F_E از هر فرد در یک نسل وجود دارد، که در بخش بعدی توضیح داده می شود.

LBSA 4

4.1 انگیزه

انگیزه اصلی در ایجاد LBSA، ترکیب ایده های یادگیری TLBO در BSA بنیادی برای بهبود عملکرد سراسری آن است. در الگوریتم BSA اولیه، زمانی که تنوع جمعیت در آنافاز (مرحله ای از تقسیم میتوز، که در آن دو نوار سازنده کروموزوم، از هم جدا می شوند) تکاملی تضعیف می شود، توانایی تکامل افراد شروع به ضعیف شدن می کند. این پدیده فرد را از پیدا کردن بهینه سازی سراسری منصرف می کند. علاوه بر این، این عمل نشان می دهد که عملگر یادگیری می تواند سازگاری جمعیت را بهبود بخشد و یادگیری از بهترین فرد می تواند سرعت همگرایی الگوریتم را بهبود دهد و همچنین ظرفیت بهره برداری از الگوریتم را افزایش دهد. در هر حال، این پدیده تنوع جمعیت و ظرفیت شناسایی الگوریتم را با سرعت همگرایی سریعی کاهش خواهد داد. چگونگی افزایش توانایی

شناسایی الگوریتم از طریق بهبود تنوع جمعیتی با اصلاح فرآیند بروز رسانی افراد برای بهبود ویژگی های کلی الگوریتم بهینه سازی بسیار مهم می باشد. از این رو، LBSA پیشنهادی عملکرد سراسری BSA بنیادی را توسط اصلاح فرآیند های جهشی بهبود می بخشد.

4.2 جهش LBSA

در BSA بنیادی، تنها از اطلاعات پیشین و موقعیت فعلی یک فرد برای تولید موقعیت جدید استفاده می شود. در این الگوریتم افراد نمی توانند دانش را از آموزش دهنده کل گروه یادگیرند. برخی از روش های EA که می توانند بهترین فرد را ردیابی می کنند ممکن است سرعت همگرایی الگوریتم را افزایش دهند. برای بهبود توانایی یادگیری BSA، هدایت کننده یادگیری بهترین فرد را در فرآیند جهش الگوریتم معرفی می کند که به شرح زیر می باشد:

$$M = P + F \cdot (0.5 \cdot (oldP - P) + 0.5 \cdot rand(.) \cdot (Teacher - P)) \quad (11)$$

که آموزش دهنده بهترین فرد از نسل فعلی است، $F=3 \cdot rand$ و معانی پارامترهای دیگر همان چیزی هستند که در BSA بنیادی وجود دارد.

روش های یادگیری TBLO قبل از آنکه اصلاح شود در LBSA به کار رفته است. روش جدید شامل 3 بخش می باشد. بخش اول، هر فرد دانش را از یک فرد تصادفی و از جمعیت حاضر، مانند همان چیزی که در روش TBLO است یاد می گیرد. بخش دوم، هر فرد دانش را از بهترین فرد، که متفاوت از TBLO است یاد می گیرد زیرا از موقعیت میانگین جمعیت حاضر استفاده نمی شود. علاوه بر این، برای افزایش تنوع افراد تولید شده، اجتناب از بدترین فرد نسل حاضر در معادله بروز رسانی در نظر گرفته می شود. در مقابل TBLO، سه روش ذکر شده در LBSA را در یک معادله یکپارچه کرده است و هر فرد تنها یک F_E را در هر نسل کنترل می کند. جزئیات دقیق به شرح زیر می باشد:

$$\begin{cases} M_{i,j} = P_{i,j} + rand \cdot (P_{i,j} - P_{k,j}) + rand \cdot (Teacher_{1,j} - P_{i,j}) - rand \cdot (Worst_{1,j} - P_{i,j}) \\ \quad \text{اگر فرد } i \text{ ام نسبت به فرد } k \text{ ام بهتر باشد} \\ M_{i,j} = P_{i,j} + rand \cdot (P_{k,j} - P_{i,j}) + rand \cdot (Teacher_{1,j} - P_{i,j}) - rand \cdot (Worst_{1,j} - P_{i,j}) \\ \quad \text{در غیر اینصورت} \end{cases} \quad (12)$$

که $P_{i,j}$ بیت j ام از فرد i ام می باشد، $i=1, 2, \dots, N$ ، $j=1, 2, \dots, D$ ، مقدار بیت j ام از فرد k ام می باشد، که از جامعه بصورت تصادفی انتخاب شده و متفاوت از فرد i ام است. $M_{i,j}$ مقدار بیت j ام از فرد i ام است که بعد از عملگر جهش بکار می رود. علاوه براین، آموزش دهنده و بدترین فرد، به ترتیب بهترین و بدترین موقعیت از نسل حاضر می باشند. ما مشاهده کردیم که معادلات 11 و 12 در فرآیند جهش LBSA بصورت تصادفی انتخاب شده اند. شبه کد نوشته شده برای LBSA در الگوریتم 1 نشان داده شده است.

4.3 تجزیه و تحلیل تنوع BSA و LBSA

به منظور بررسی تنوع، BSA بنیادی با عملگرهای اصلاح شده بهبود یافته اند و توابع F5، F6، F9 و F15 در CEC2005 برای آزمایش تغییر تنوع به عنوان نسل های افزایشی استفاده شده اند. بسیاری از اندازه گیرهای گوناگون، مانند SPD، HPD [38]، روش های مبتنی بر میانگین فاصله همینگ (Hamming) همه ی افراد، فاصله بین موقعیت همه ی افراد و موقعیت مرکزی جمعیت و آنتروپی [4] وجود دارند. به سادگی و بطور مستقیم تنوع BSA و LBSA تجزیه و تحلیل می شود، روشی ساده شده براساس متوسط فاصله همینگ همه افراد در این مقاله انتخاب شده است. برای مقایسه منصفانه تنوع الگوریتم های BSA و LBSA، فاصله بین دو فرد در محدوده [0, 1] نرمال سازی می شود. تعریف تنوع جمعیت به شرح زیر می باشد:

Algorithm 1 . Pseudo code of LBSA ().

```

1 Begin
2 Initialize  $N$  (number of population),  $D$  (dimension), maxFEs, maxgen, mixrate,  $low_{1:D}$ ,  $up_{1:D}$ ;
% Initialize population;
3 for  $i = 1:N$ 
4   for  $j = 1:D$ 
5      $P_{ij} = low_j + rand * (up_j - low_j)$ ;
6     old  $P_{ij} = low_j + rand * (up_j - low_j)$ ;
7   endfor
8 endfor
9 Evaluate all individuals;
10 memorize the best (Teacher) and the worst individual (worst);
11 For gen = 1:maxgen
% Selection-I
12   if ( $a < b$ ),  $b \sim U(0, 1)$ ) then oldP=P end;
13   oldP= randperm (oldP); % 'permuting' arbitrary changes in positions of two individuals in oldP
% Generate trial population
% Mutation
14   for  $i = 1:N$ 
15     if ( $a < b$ ),  $b \sim U(0, 1)$ )
16       the individual is mutated by Eq. 11, generate partly individuals of trial population T;
17     else
18       the individual is mutated by Eq. 12, generate the remainder individuals of trial population T;
19     end
20   endfor
% Crossover
21   map $_{1:N,1:D} = 1$ ; %Initial map matrix
22   if ( $a < b$ ),  $b \sim U(0, 1)$ )
23     for  $i = 1:N$ 
24        $u = randperm(D)$ ;
25       map $_{i,u(1:ceil(mixrate * rand * D))} = 0$ ;
26     endfor
27   else
28     for  $i = 1:N$ 
29       map $_{i,rand(D)} = 0$ ;
30     endfor
31   end
32   for  $i = 1:N$ 
33     for  $j = 1:D$ 
34       if map $_{i,j} = 1$ 
35          $T_{ij} = P_{ij}$ ;
36       end
37     endfor
38   endfor
% Boundary control mechanism
39   for  $i = 1:N$ 
40     for  $j = 1:D$ 
41       if ( $T_{ij} < low_j$ ) or ( $T_{ij} > up_j$ )
42          $T_{ij} = low_j + rand * (up_j - low_j)$ ;
43       end
44     endfor
45   endfor
% Selection-II
46   Evaluate trial population T;
47   for  $i = 1:N$ 
48     if  $T_i$  is better than  $P_i$ 
49        $P_i = T_i$ ;
50       fitness( $P_i$ )=fitness( $T_i$ );
51     end
52   endfor
53   renew Teacher and worst
54   output the best solution min(fitness(P))
54 endFor

```

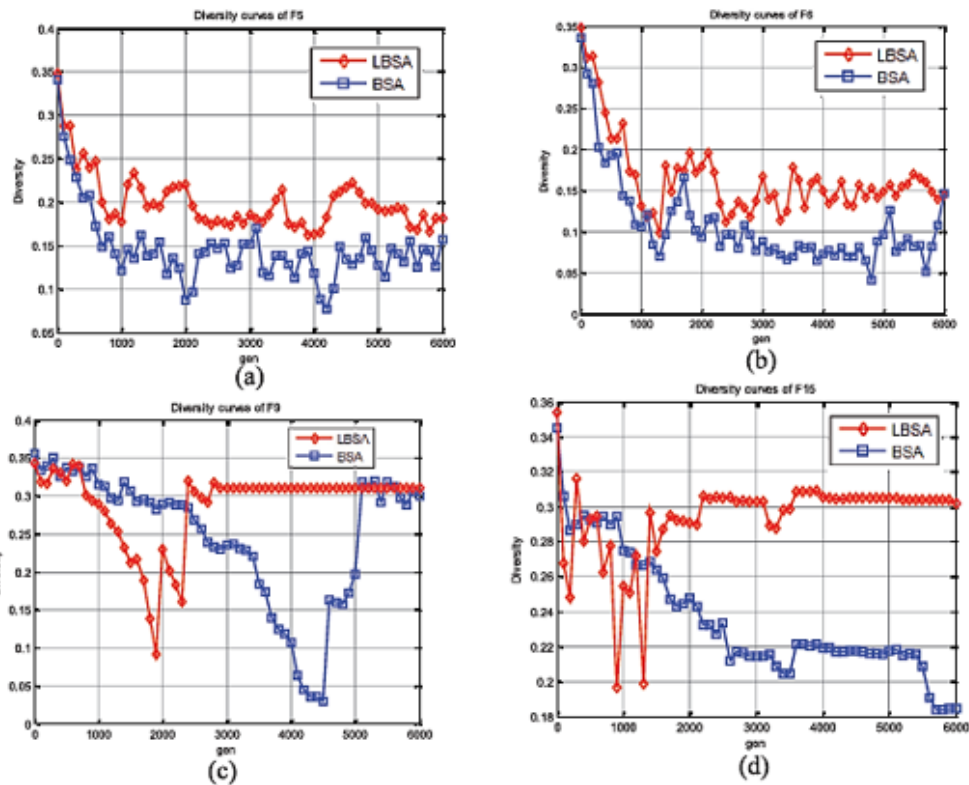


Fig. 1. The diversities curve of LBSA and BSA.

تعریف 1: فاصله همینگ بین فرد i ام و (p_i) و فرد l ام (p_l) در رابطه 13 بیان شده است:

$$H(p_i, p_l) = \sum_{j=1}^D |p_{i,j} - p_{l,j}| \quad (13)$$

تعریف 2: فاصله نرمال شده بین فرد i ام (p_i) و فرد l ام (p_l) در رابطه 14 بیان شده است:

$$H^*(p_i, p_l) = H(p_i, p_l) / \max\{H(p_m, p_n), m = 1, 2, \dots, N-1; n = m+1, m+2, \dots, N\} \quad (14)$$

تعریف 3: متوسط فاصله همینگ بین جمعیت در هر تکرار در رابطه 15 نشان داده شده است:

$$\bar{H}(T) = \frac{2 \sum_{i=1}^{N-1} \sum_{j=i+1}^N H^*(p_i, p_j)}{N^*(N-1)} \quad (15)$$

پارامترهای آموزش عبارتند از: مقدار جمعیت 50 نفر است، شرط پایان الگوریتم حداکثر تعداد تکرارها است، مقدار تکرار 6000 است، ابعاد توابع 30 است و دو الگوریتم آزمایش شده بیش از 30 بار بطور مستقل از هم اجرا شده اند. تغییرات تنوع میانگین در شکل 1 نشان داده شده است و بیان می کند که تنوع میانگین LBSA نسبت به BSA بنیادی برای بسیاری از تکرارها بهتر است. این کار به LBSA کمک می کند تا براحتی از نقطه بهینه محلی دور

شود. شکل 1 (الف) و (ب) نشان می دهد که تنوع LSBA تقریباً نسبت به BSA بهتر است، و تنوع دو الگوریتم در تمام مسیر تکامل مرتعش می باشد. شکل 1 (ج) و (د) نشان می دهند که تنوع LBSA نسبت به BSA در مرحله شروع تکامل بدتر می باشد اما نتایج مخالفی در آنافاز تکاملی بدست آمده است. شکل 1 (ج) و (د) نشان می دهند که تنوع الگوریتم ها در پایان تکامل برای الگوریتم هایی که به نقطه بهینه محلی یا سراسری می رسند تقریباً بدون تغییر هستند.

5. شبیه سازی آزمایش ها

برای آزمایش عملکرد LBSA، سه آزمایش سنجشی انجام شده است. برای نشان دادن اثربخشی الگوریتم پیشنهادی، سه نوع از الگوریتم PSO (PSOFIPS) [20] ، PSO (PSOFDR) [23] و CLPSO [15]، دو نوع از الگوریتم DE (jDE) [1] و SaDE [24] سه نوع از الگوریتم TLBO که به تازگی پیشنهاد شده است (TLBO) [31]، ETLBO [29] و DGSTLBO [45] و BSA بنیادی [5] به عنوان الگوریتم های مقایسه ای استفاده شده است. الگوریتم های مرتبط با LBSA عبارتند از ایده های یادگیری در PSO و TLBO، اطلاعات پیشین در BSA بنیادی و عملگر ترکیب در DE می باشند. از این رو، این الگوریتم ها یا انواع آنها برای مقایسه با LBSA انتخاب شده اند. برای نشان دادن اثربخشی الگوریتم پیشنهادی، CEC2005 [35] و CEC2014 [16, 18] به عنوان مسائل تابع سنجشی بکار رفته اند. آموزش شبکه های عصبی مصنوعی (ANN) برای پیش بینی سری های زمانی و مدلسازی سیستم غیرخطی به عنوان مسائل کاربردی استفاده شده است.

5.1 راه اندازی آزمایشی

اطلاعات دقیقی باتوجه به مسائل سنجشی برای CEC2005 در مقاله [35] ارائه شده است. 30 مسئله سنجشی برای CEC2014 در مقاله [16] ارائه شده است. سیستم های غیرخطی تک ورودی تک خروجی (SISO) و چند ورودی تک خروجی (MISO) [39] و دو مسئله ی پیش بینی سری های زمانی کلاسیک (سری های زمانی

آشوبی مکی-گلاس و سری های زمانی آشوبی باکس-جنکینز [33,34]) در آزمایش ها پیش بینی شده اند. مدل پیش بینی پرسپترون چند لایه (MLP) و پارامترهای آن توسط EAهای مختلف آموزش داده شدند.

5.2 تنظیمات پارامتر

همه ی آزمایشات بر روی ماشینی مشابه با استفاده از برنامه MATLAB2012a انجام شده است. هر الگوریتم بطور مستقل برای 30 بار اجرا شده است. برای همه الگوریتم ها، مقدار جمعیت 50 نفر در نظر گرفته شده است. حداکثر F_E به عنوان معیار توقف برای همه الگوریتم ها استفاده می شود. برای CEC2005 و CEC2014 ، حداکثر F_E بر روی 5000 D (ابعاد متغییر است) تنظیم شده است. علاوه بر این، توابع 10 D و 30 D برای CEC2005 شبیه سازی شده اند و توابع 30 D برای CEC2014 آزمایش شده اند. برخی از پارامترهای دیگر الگوریتم های مقایسه به شرح زیر ذکر شده اند:

- PSOFIPS [20]: $w = 0.7298$;
- PSOFDR [23]: $w_{min} = 0.4$, $w_{max} = 0.9$, $\psi_1 = 1$, $\psi_2 = 1$, $\psi_3 = 2$;
- CLPSO [15]: $cc = [1.49445 \ 1.49445]$; $iwt = 0.9 - (1: maxgen) * (0.7 / maxgen)$

$$P_{e_i} = 0.05 + 0.45 * \frac{\exp(\frac{10(i-1)}{N-1}) - 1}{\exp(10) - 1} \quad (N \text{ اندازه جامعه است})$$

- jDE [1]: $F = 0.5$, $CR = 0.9$;
- SaDE [24]: $F \sim N(0.5, 0.3)$, $CR_0 = 0.5$, $CR \sim N(CR_m, 0.1)$, $LP = 50$;
- ETLBO [29]: elite size = 2
- DGSTLBO[45]: m (اندازه گروه) = 5, p (دوره نوسازی) = 5, P_c (احتمال یادگیری) = 5;

5.3 آزمایش های CEC2005

5.3.1 مقایسه درستی راه حل تابع 10 D در CEC2005

نتایج شبیه سازی برای تابع 10D در CEC2005 در جدول 1 نشان داده شده است. نتایج نشان می دهند که با توجه به مقدار میانگین، LBSA عملکرد بهتری نسبت به 9 الگوریتم دیگر برای توابع F22, F15, F10, F9 و F23 دارد. jDE عملکرد بهتری نسبت به نه الگوریتم دیگر برای توابع F3, F6, F7 و F17 دارد. برای تابع F3

مقدار میانگین jDE به راه حل بهینه سازی نظری نزدیکتر است و انحراف معیار jDE (Std) در بین همه ی الگوریتم ها کوچکتر است. $LBSA$ نمی تواند برای راه حل بهینه سازی نظری در همه ی 30 بار اجرا شدن همگرا شود، و مقدار میانگین و انحراف معیار آن نسبت به jDE و $SaDE$ بدتر است. رتبه $LBSA$ در شرایط میانگین 3 می باشد. $SaDE$ نسبت به نه الگوریتم دیگر در شرایط میانگین برای دو تابع $F12$ و $F16$ عملکرد بهتری دارد. مقدار میانگین $PSOFIPS$ نسبت به الگوریتم های دیگر برای توابع $F21$ و $F25$ بهتر می باشد. $PSOFDR$ عملکرد بهتری نسبت به دیگر الگوریتم ها در شرایط میانگین برای توابع $F8$ ، $F11$ و $F14$ دارد. BSA نسبت به الگوریتم های دیگر برای توابع $F13$ ، $F18$ و $F20$ بهتر می باشد. برای تابع $F20$ ، بهترین راه حل های $PSOFIPS$ ، $TLBO$ ، BSA و $LBSA$ شبیه به راه حل بهینه سازی نظری می باشند؛ که بهینه سازی سراسری در 30 بار اجرا شدن این سه الگوریتم وجود دارد. برای تابع $F1$ ، همه الگوریتم ها به مقدار بهینه سراسری بجز برای $PSOFDR$ همگرا می شوند. همه ی 10 الگوریتم تقریباً مقدار بهینه سراسری تابع $F2$ را بدست می آورند. برای تابع $F4$ ، $PSOFIPS$ و $CLPSO$ نمی توانند به مقدار بهینه سراسری همگرا شوند. برای تابع $F5$ ، سه الگوریتم نمی توانند مقدار بهینه سراسری را پیدا کنند. جدول 1 همچنین نشان می دهد که $LBSA$ برای 10 تابع از 25 تابع در شرایط میانگین دارای رتبه اول است که نسبت به 9 الگوریتم دیگر بالاتر می باشد. رتبه متوسط $LBSA$ نیز بهتر از ده الگوریتم برای $CEC2005$ می باشد. علاوه براین، در آن یک پدیده که راه حل بهترین میانگین و انحراف معیار یک الگوریتم با ویژگی مخالف است وجود دارد. برای مثال، انحراف معیار $LBSA$ کمترین بود، اما مقدار میانگین برای تابع $F16$ بهترین نبود، و بدین معنی است که راه حل $LSBA$ از 8 الگوریتم دیگر به نسبت بهتر بود اما انحراف معیار برای تابع $F20$ بهترین نبود. دلیل این پدیده به شرح زیر توضیح داده شده است. برای یک مشکل چندگانه (چند کیفیتی) با 5 نقطه اکسترمم در شکل 2، الگوریتم A و B برای یافتن بهینه سازی سراسری با اجرای m حالت مستقل استفاده می شود. اگر الگوریتم A برای نقطه 2 در m اجرا شود، الگوریتم B در نقطه 4 با $m-1$ اجرا می شود و در نقطه 5 باید یکبار اجرا شود. بهترین میانگین الگوریتم B از الگوریتم A بهتر خواهد بود، اما انحراف معیار الگوریتم A ممکن است نسبت به الگوریتم B کمتر باشد. در شرایط بهترین میانگین در حالت کلی

عملکرد راه حل الگوریتم B از الگوریتم A بهتر است.

Table 1
Comparative results of ten algorithms for 10D problems from CEC2005.

F	AL	PSOFIPS	PSOFDR	CLPSO	JDE	SaDE	TLBO	ETLBO	DGSTLBO	BSA	LBSA
F1	mean	-450.000	-439.674	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000
	std.	0.000	32.653	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
	best	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000
	Rank	1	2	1	1	1	1	1	1	1	1
F2	mean	-450.000	-450.000	-449.676	-450.000	-450.000	-450.000	-450.000	-450.000	-449.997	-450.000
	std.	0.000	0.000	0.177	0.000	0.000	0.000	0.000	0.000	0.005	0.000
	best	-450.000	-450.000	-449.906	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000	-450.000
	Rank	1	1	3	1	1	1	1	1	2	1
F3	mean	114,431,841	143,065,100	695,430,984	-237.160	546,821	70,188,530	132,295,917	55,887,005	21,518,124	5652,945
	std.	54,898,334	156,627,508	263,113,140	363.050	2552,898	47,419,217	98,983,396	82,010,530	18,993,641	7686,985
	best	48,691,653	6576,186	333,184,289	-450.000	-449,996	22,503,152	23,199,940	7846,953	3316,003	251,786
	Rank	7	9	10	1	2	6	8	5	4	3
F4	mean	-450.000	-438,829	-445,693	-450.000	-450.000	-450.000	-450.000	-450.000	-449,800	-450.000
	std.	0.000	23,550	2,683	0.000	0.000	0.000	0.000	0.000	0.306	0.000
	best	-450.000	-450.000	-449,361	-450.000	-450.000	-450.000	-450.000	-450.000	-449,994	-450.000
	Rank	1	4	3	1	1	1	1	1	2	1
F5	mean	-233,009	-310.000	-310.000	-299,093	-310.000	-310.000	-310.000	-152,429	-310.000	-310.000
	std.	33,727	0.000	0.000	15,577	0.000	0.000	0.000	261,668	0.000	0.000
	best	-289,340	-310.000	-310.000	-310.000	-310.000	-310.000	-310.000	-310.000	-310.000	-310.000
	Rank	3	1	1	2	1	1	1	4	1	1
F6	mean	394,658	399,415	391,599	390,399	390,848	392,592	392,167	395,307	392,105	390,548
	std.	0.405	18,471	1,610	1,261	1,529	3,041	2,313	2,735	2,741	1,112
	best	393,841	390,002	390,348	390.000	390.000	390.000	390,000	390,179	390,091	390,001
	Rank	8	10	4	1	3	7	6	9	5	2
F7	mean	-179,810	1087,288	1087,208	-179,965	1087,046	1087,046	1087,046	-167,902	1087,082	1087,046
	std.	0,098	0,197	0,057	0,029	0,000	0,000	0,000	4,011	0,076	0,000
	best	-179,949	1087,226	1087,046	-180,000	1087,046	1087,046	1087,046	-172,669	1087,046	1087,046
	Rank	2	7	6	1	4	4	4	3	5	4
F8	mean	-119,640	-119,714	-119,624	-119,661	-119,666	-119,628	-119,648	-119,653	-119,681	-119,643
	std.	0,090	0,075	0,081	0,074	0,082	0,087	0,066	0,089	0,085	0,053
	best	-119,851	-119,800	-119,792	-119,791	-119,813	-119,831	-119,718	-119,777	-119,812	-119,728
	Rank	8	1	10	4	3	9	6	5	2	7
F9	mean	-329,333	-327,314	-330.000	-330.000	-330.000	-322,342	-322,737	-322,409	-330.000	-330.000
	std.	0,723	1,487	0.000	0.000	0.000	2,928	2,696	2,528	0.000	0.000
	best	-330.000	-329,005	-330.000	-330.000	-330.000	-326,020	-327,015	-325,025	-330.000	-330.000
	Rank	2	3	1	1	1	5	4	6	1	1
F10	mean	-317,409	-319,259	-316,698	-322,417	-322,339	-319,885	-321,513	-318,339	-320,479	-323,493
	std.	5,428	6,162	3,125	2,704	3,604	4,132	3,593	4,213	3,542	1,987
	best	-324,188	-328,010	-322,465	-326,395	-329,005	-325,025	-327,015	-324,012	-324,562	-325,724
	Rank	9	7	10	2	3	6	4	8	5	1
F11	mean	93,633	91,962	95,319	96,078	92,093	94,002	94,632	93,193	94,889	95,188
	std.	0,536	1,023	0,572	0,698	2,355	1,652	0,997	1,049	1,196	0,746
	best	92,922	90,702	94,425	94,895	90,000	91,059	92,619	91,772	92,408	93,737
	Rank	4	1	9	10	2	5	6	3	7	8
F12	mean	-422,531	-203,253	-363,666	-186,308	-456,999	1445,385	794,693	908,556	-438,290	-444,398
	std.	47,468	507,838	65,389	84,882	4,832	5027,194	2860,501	3344,475	16,021	16,545
	best	-455,719	-459,496	-431,128	-323,775	-460.000	-460.000	-460.000	-449,679	-455,477	-459,985
	Rank	4	6	5	7	1	10	8	9	3	2
F13	mean	-128,810	-129,352	-129,564	-129,675	-129,486	-129,196	-129,044	-129,307	-129,697	-129,666
	std.	0,146	0,271	0,118	0,058	0,088	0,165	0,256	0,160	0,118	0,073
	best	-129,109	-129,745	-129,769	-129,756	-129,689	-129,447	-129,384	-129,481	-129,932	-129,830
	Rank	10	6	4	2	5	8	9	7	1	3
F14	mean	-297,170	-297,241	-296,591	-296,562	-296,912	-297,215	-297,081	-297,230	-296,694	-296,902
	std.	0,306	0,685	0,151	0,252	0,217	0,249	0,459	0,353	0,205	0,207
	best	-297,642	-298,570	-296,948	-297,118	-297,246	-297,566	-297,701	-297,724	-297,108	-297,288
	Rank	4	1	9	10	6	3	5	2	8	7
F15	mean	209,829	387,275	140,582	177,355	136,613	450,644	401,382	397,863	124,232	120,030
	std.	99,415	203,967	28,900	64,825	21,448	141,887	156,564	166,285	12,918	0,089
	best	120,460	176,891	120,002	120.000	120.000	195,411	197,129	180,374	120.000	120.000
	Rank	6	7	4	5	3	10	9	8	2	1
F16	mean	232,105	254,799	257,700	220,475	219,202	228,617	230,096	242,547	231,537	223,754
	std.	10,777	29,896	14,508	4,893	4,653	9,831	9,792	13,648	10,701	3,450
	best	221,355	222,865	223,542	214,433	215,972	219,015	217,668	223,611	209,614	218,507
	Rank	7	9	10	2	1	4	5	8	6	3
F17	mean	251,164	247,905	269,953	222,366	224,970	246,701	228,562	236,482	249,588	241,073
	std.	19,976	21,479	16,875	19,527	7,003	19,773	5,540	11,421	10,448	11,036
	best	216,798	219,166	252,680	172,389	218,009	218,722	222,809	217,019	237,089	227,764
	Rank	9	7	10	1	2	6	3	4	8	5

(continued on next page)

Table 1 (continued)

F	AL	PSOFIPS	PSOFDR	CLPSO	jDE	SaDE	TLBO	ETLBO	DGSTLBO	BSA	LBSA
F18	mean	580.649	864.345	702.404	738.946	760.000	709.009	715.153	858.448	393.335	603.702
	std.	277.920	96.241	86.522	235.263	158.114	237.366	240.232	148.634	155.192	253.504
	best	310.000	700.558	559.128	310.000	310.000	310.000	393.632	597.895	310.000	310.000
	Rank	2	10	4	7	8	5	6	9	1	3
F19	mean	442.020	864.003	752.056	622.746	740.949	756.348	716.366	912.207	404.878	572.111
	std.	214.463	131.102	46.800	269.169	162.827	201.804	227.717	115.327	162.270	278.437
	best	310.000	698.725	656.476	310.000	310.000	417.269	366.021	634.105	310.000	310.000
	Rank	2	9	7	4	6	8	5	10	1	3
F20	mean	666.374	896.631	711.274	843.889	810.000	748.635	791.997	956.972	410.210	442.654
	std.	251.178	117.945	75.428	40.267	0.000	186.662	164.780	80.840	177.868	211.159
	best	310.000	693.240	566.636	830.917	810.000	310.000	467.410	810.000	310.000	310.000
	Rank	3	9	4	8	7	5	6	10	1	2
F21	mean	830.619	1212.545	846.708	1093.908	930.000	1110.454	931.239	1035.818	832.592	910.002
	std.	222.507	400.425	28.555	267.013	170.294	367.780	360.290	366.993	86.672	171.591
	best	660.000	660.000	790.540	860.000	660.000	660.000	660.000	660.000	585.919	660.019
	Rank	1	10	3	8	5	9	6	7	2	4
F22	mean	1131.082	1177.217	1141.724	1110.531	1117.446	1150.209	1135.155	1155.322	1079.861	1074.270
	std.	3.327	79.315	7.787	83.245	5.557	29.625	24.736	61.423	148.046	145.718
	best	1125.586	1109.829	1131.022	886.118	1108.033	1116.253	1110.458	1094.723	660.000	660.000
	Rank	5	10	7	3	4	8	6	9	2	1
F23	mean	1069.522	1431.577	906.039	1282.261	1035.216	1178.115	1237.380	1351.502	918.677	892.609
	std.	179.445	215.479	42.468	261.521	178.858	232.518	257.118	254.423	1.797	56.624
	best	919.468	919.468	785.173	919.468	785.173	919.468	919.468	919.468	914.095	785.173
	Rank	5	10	2	8	4	6	7	9	3	1
F24	mean	588.505	1126.804	696.247	636.172	460.000	460.000	460.000	490.000	460.000	460.000
	std.	86.471	239.476	295.248	3.399	0.000	0.000	0.000	94.868	0.000	0.000
	best	460.001	760.000	460.211	628.653	460.000	460.000	460.000	460.000	460.000	460.000
	Rank	3	6	5	4	1	1	1	2	1	1
F25	mean	612.785	1339.389	1079.655	634.054	1082.075	1078.221	1076.067	1122.095	1080.375	1079.394
	std.	80.691	217.394	2.151	7.695	1.638	2.460	2.650	484.200	2.634	2.258
	best	460.000	1071.868	1077.376	613.127	1079.380	1074.200	1071.563	460.000	1074.953	1075.267
	Rank	1	10	6	2	8	4	3	9	7	5
Average rank		4.32	6.24	5.52	3.84	3.32	5.32	4.84	5.96	3.24	2.84




Fig. 2. Multimodal problems with five extremums.

مقادیر برجسته در جدول 3 بهترین راه حل ها هستند. نتایج برای CEC2005 نشان می دهد که LBSA عملکردی قیاس پذیر را نتیجه می دهد، اگرچه همواره نسبت به دیگر روش ها در تمام جنبه ها بهتر نیست.

5.3.2 مقایسه درستی راه حل تابع 30 D در CEC2005

در این آزمایشات، تابع برازش برای تفاوت بین راه حل حقیقی الگوریتم ها و بهینه سازی نظری توابع انتخاب شده بود. اگر راه حل واقعی i ام الگوریتم f_i باشد، پس تابع برازش می تواند بصورت $|f_i - F_i^*|$ بیان شود. ابعاد توابع

در CEC2005 در این آزمایش 30 بود. بهترین، میانگین و انحراف معیار راه حل ها که بیش از 30 بار اجرا می شود برای 10 الگوریتم در جدول 2 نشان داده شده است. علاوه بر این، رتبه و رتبه میانگین 10 الگوریتم برای 25 تابع نیز داده شده است. جدول 2 نشان می دهد که رتبه LBSA در شرایط میانگین بهترین راه حل برای توابع F1, F12, F13, F16, F17, F21, F23, و F24 اول بود. jDE برای توابع F1, F4, F6, F9, F10, F18, F19, F20 و F22 رتبه اول شده است. اولین رتبه از دیگر توابع توسط الگوریتم های دیگر به اشتراک گذاشته شد. در شرایط کل تعداد رتبه های اول، jDE عملکرد بهتری نسبت به 9 الگوریتم دیگر و LBSA در مکان دوم بود. بهترین نتایج در جدول 2 بصورت برجسته نشان داده شده است. انحراف معیار LBSA نسبت به الگوریتم های دیگر برای توابع F12, F16, F19, F24 و F25 کوچکتر می باشد و الگوریتم jDE عملکرد بهتری نسبت به دیگر الگوریتم ها برای توابع F3, F4, F9, F10, F13 و F20 دارد. کوچکترین راه حل ها از نظر انحراف معیار برای دیگر توابع توسط هشت الگوریتم بدست می آید و جمع آنها برای هر الگوریتم کمتر از 6 بود. نتایج آماری در جدول 2 نشان می دهد که عملکردهای سراسری jDE و LBSA نسبت به دیگر الگوریتم ها بهتر هستند اگرچه jDE نسبت به LBSA در این آزمایش کمی بهتر بود. برای نمایش فرآیند همگرایی از 10 الگوریتم برای برخی از توابع در CEC2005، شکل 3 شامل هشت نمودار همگرایی برای 30 D توابع F1, F2 (توابع تک مدی)، F12, F13 (توابع چند مدی)، F16, F17, F23 و F24 (تابع ترکیبی) است. این شکل نشان می دهد که سرعت همگرایی SaDE نسبت به دیگر الگوریتم ها برای F1 سریع تر می باشد و ETLBO عملکرد بهتری نسبت به دیگر الگوریتم ها برای تابع F2 دارد. برای F12, F13, F16 و F17، LBSA عملکرد سریع تری دارد. برای F23، سرعت همگرایی SaDE، BSA و LBSA تقریباً مشابه هم هستند. برای F24، SaDE، TLBO، ETLBO، BSA و LBSA تقریباً سرعت همگرایی مشابه ای دارند. جدول 2 و شکل 3 همچنین نشان می دهند که LBSA عملکردی قابل مقایسه با الگوریتم های دیگر می دهد، اما همیشه بهترین الگوریتم برای همه اندازه گیرهای آماری نیست. مقایسه عملکرد بین LBSA و jDE نشان می دهد که، ما می توانیم تشخیص دهیم که میانگین بهترین راه حل jDE برای 10 تابع کوچکترین بود، اما LBSA کوچکترین میانگین بهترین راه حل را برای هشت تابع ارائه

می دهد. رتبه متوسط در شرایط میانگین بهترین راه حل jDE برابر با 3.08 بود که نسبت به مقدار (3.20)

LBSA بهتر است. مقایسه نشان می دهد که jDE عملکرد بهتری نسبت به LBSA برای این 25 تابع دارد.

Table 2
Comparative results of ten algorithms for 30D functions from CEC2005(the bold is the best solution).

F	AL	PSOFIPS	PSOFDR	CLPSO	jDE	SaDE	TLBO	ETLBO	DGSTLBO	BSA	LBSA
F1	mean	1.057E-06	9.933E+02	4.839E-10	0.000E+00	0.000E+00	5.836E-26	3.138E-27	2.252E-06	3.995E-16	0.000E+00
	std.	3.274E-07	1.632E+03	1.409E-10	0.000E+00	0.000E+00	2.769E-26	1.661E-27	3.901E-06	2.267E-16	0.000E+00
	best	7.480E-07	0.000E+00	3.244E-10	0.000E+00	0.000E+00	2.640E-26	1.379E-27	2.565E-13	1.713E-16	0.000E+00
	Rank	7	9	6	1	1	4	3	8	5	1
F2	mean	4.560E+02	9.374E+01	6.355E+03	1.945E-03	8.734E-03	7.480E-05	6.632E-05	5.228E+02	2.644E+03	4.995E-02
	std.	6.497E+01	8.638E+01	7.050E+02	3.259E-03	4.026E-03	3.423E-05	7.342E-05	1.901E+02	2.038E+02	4.852E-02
	best	3.818E+02	8.972E-03	5.676E+03	5.487E-05	4.213E-03	3.527E-05	2.493E-06	3.241E+02	2.450E+03	1.714E-02
	Rank	7	6	10	3	4	2	1	8	9	5
F3	mean	1.265E+07	1.757E+06	4.814E+07	6.223E+05	4.385E+05	1.344E+06	1.331E+06	5.770E+06	3.069E+06	9.240E+05
	std.	1.170E+06	6.131E+05	5.129E+06	5.257E+04	1.529E+05	6.881E+05	2.882E+05	3.854E+06	2.791E+05	3.486E+05
	best	1.138E+07	1.084E+06	4.296E+07	5.870E+05	3.380E+05	6.838E+05	1.128E+06	2.335E+06	2.784E+06	7.127E+05
	Rank	9	5	10	2	1	5	4	8	7	3
F4	mean	3.019E+03	7.308E+02	1.613E+04	1.621E+01	4.769E+02	2.128E+03	8.611E+02	2.102E+03	9.404E+03	7.097E+02
	std.	8.707E+02	2.258E+02	1.800E+03	1.004E+01	7.790E+02	2.915E+03	7.453E+02	2.238E+03	7.848E+02	4.298E+02
	best	2.016E+03	5.912E+02	1.505E+04	9.789E+00	2.337E+01	1.736E+02	4.067E+02	6.345E+02	8.510E+03	2.659E+02
	Rank	8	4	10	1	2	7	5	6	9	3
F5	mean	3.104E+03	6.156E+03	4.315E+03	2.067E+03	2.427E+03	4.546E+03	4.161E+03	9.835E+03	3.334E+03	3.029E+03
	std.	1.055E+02	1.750E+03	9.405E+02	9.514E+02	2.732E+02	3.140E+02	4.601E+02	1.524E+03	1.767E+02	7.939E+02
	best	3.009E+03	5.077E+03	3.523E+03	1.098E+03	2.141E+03	4.197E+03	3.678E+03	8.119E+03	3.130E+03	2.501E+03
	Rank	4	9	7	1	2	8	6	10	5	3
F6	mean	2.891E+01	1.638E+07	3.974E+01	5.364E+01	7.807E+01	2.297E+01	3.895E+01	2.164E+04	7.803E+01	2.958E+01
	std.	2.546E+00	2.646E+07	2.123E+01	3.630E+01	2.212E+00	2.780E+00	3.169E+01	3.596E+04	3.027E+01	4.229E+01
	best	2.714E+01	2.290E+02	1.529E+01	1.174E+01	7.557E+01	2.109E+01	2.027E+01	1.766E+02	4.494E+01	3.069E+00
	Rank	2	10	5	6	8	1	4	9	7	3
F7	mean	3.846E-01	4.918E+03	4.696E+03	9.037E-03	4.696E+03	4.696E+03	4.696E+03	9.207E+02	4.696E+03	4.696E+03
	std.	9.646E-02	3.844E+02	0.000E+00	1.421E-03	3.750E-12	1.575E-12	9.095E-13	1.570E+02	1.720E-08	1.575E-12
	best	2.859E-01	4.696E+03	4.696E+03	7.396E-03	4.696E+03	4.696E+03	4.696E+03	7.393E+02	4.696E+03	4.696E+03
	Rank	2	5	4	1	4	4	4	4	4	4
F8	mean	2.093E+01	2.092E+01	2.093E+01	2.098E+01	2.097E+01	2.098E+01	2.089E+01	2.095E+01	2.098E+01	2.096E+01
	std.	1.087E-02	2.802E-02	8.812E-02	3.299E-02	2.665E-02	1.689E-02	6.181E-02	6.464E-02	4.595E-02	5.689E-02
	best	2.092E+01	2.089E+01	2.085E+01	2.095E+01	2.095E+01	2.097E+01	2.084E+01	2.088E+01	2.093E+01	2.091E+01
	Rank	3	2	3	7	6	7	1	4	7	5
F9	mean	5.904E+01	5.164E+01	5.082E-04	0.000E+00	3.317E-01	9.618E+01	6.567E+01	9.220E+01	2.277E+00	1.184E-15
	std.	1.441E+01	5.605E+00	2.078E-04	0.000E+00	5.744E-01	2.185E+01	3.011E+01	1.580E+01	1.295E+00	2.051E-15
	best	4.240E+01	4.754E+01	2.719E-04	0.000E+00	0.000E+00	8.258E+01	4.179E+01	8.258E+01	1.134E+00	0.000E+00
	Rank	7	6	3	1	4	10	8	9	5	2
F10	mean	1.822E+02	1.141E+02	1.647E+02	5.881E+01	7.975E+01	9.228E+01	9.913E+01	8.652E+01	8.281E+01	7.969E+01
	std.	5.261E+00	1.892E+01	5.872E+00	3.873E+00	4.349E+01	4.150E+01	1.259E+01	7.217E+00	1.541E+01	7.575E+00
	best	1.788E+02	9.451E+01	1.608E+02	5.441E+01	3.022E+01	5.771E+01	8.743E+01	8.107E+01	6.963E+01	7.131E+01
	Rank	10	8	9	1	3	6	7	5	4	2
F11	mean	2.879E+01	1.803E+01	2.798E+01	3.317E+01	2.997E+01	3.467E+01	3.714E+01	2.548E+01	3.091E+01	2.839E+01
	std.	2.252E+00	2.803E+00	1.205E+00	2.996E+00	1.669E+00	4.680E+00	1.629E+00	1.237E+00	2.377E+00	1.680E+00
	best	2.625E+01	1.551E+01	2.685E+01	3.104E+01	2.840E+01	2.930E+01	3.526E+01	2.413E+01	2.843E+01	2.661E+01
	Rank	5	1	3	8	6	9	10	2	7	4
F12	mean	2.555E+04	2.882E+04	4.411E+04	3.067E+04	6.056E+03	9.523E+03	1.550E+04	3.196E+04	2.801E+04	2.976E+03
	std.	9.809E+03	4.351E+04	3.443E+03	2.969E+03	7.626E+03	3.881E+03	1.420E+04	1.637E+04	1.173E+04	1.281E+03
	best	1.962E+04	3.259E+03	4.022E+04	2.755E+04	1.008E+03	6.257E+03	3.727E+03	1.320E+04	1.447E+04	1.698E+03
	Rank	5	7	10	8	2	3	4	9	6	1
F13	mean	1.358E+01	2.870E+00	3.409E+00	1.911E+00	4.792E+00	4.284E+00	4.063E+00	5.512E+00	2.524E+00	1.883E+00
	std.	1.025E-01	7.919E-01	2.156E-01	1.650E-02	6.707E-01	5.438E-01	1.202E+00	1.189E-01	1.192E-01	1.203E-01
	best	1.347E+01	2.293E+00	3.162E+00	1.900E+00	4.113E+00	3.912E+00	2.682E+00	5.410E+00	2.408E+00	1.771E+00
	Rank	10	4	5	2	8	7	6	9	3	1
F14	mean	1.280E+01	1.185E+01	1.312E+01	1.362E+01	1.309E+01	1.289E+01	1.309E+01	1.280E+01	1.309E+01	1.286E+01
	std.	1.223E-01	7.922E-01	1.258E-01	1.847E-01	1.846E-01	1.513E-01	7.225E-02	5.319E-01	3.739E-01	1.284E-01
	best	1.266E+01	1.112E+01	1.298E+01	1.343E+01	1.288E+01	1.278E+01	1.303E+01	1.234E+01	1.266E+01	1.276E+01
	Rank	2	1	6	7	5	4	5	2	5	3
F15	mean	3.544E+02	5.285E+02	1.214E+02	1.682E+02	2.354E+02	4.713E+02	4.746E+02	4.104E+02	7.111E+01	4.015E+02
	std.	6.430E+01	5.548E+01	2.545E+01	7.807E+01	2.047E+02	9.623E+01	4.142E+01	4.289E+01	1.159E+01	1.013E+02
	best	3.007E+02	4.831E+02	9.610E+01	7.919E+01	6.213E+00	3.977E+02	4.268E+02	3.628E+02	6.421E+01	3.000E+02
	Rank	5	10	2	3	4	8	9	6	1	7
F16	mean	2.507E+02	2.413E+02	2.018E+02	1.077E+02	1.051E+02	2.400E+02	2.652E+02	2.160E+02	1.484E+02	8.450E+01
	std.	5.874E+01	1.017E+02	2.174E+01	5.049E+01	3.010E+01	2.269E+02	1.175E+02	1.178E+01	3.611E+01	5.658E+00
	best	2.087E+02	1.245E+02	1.775E+02	7.827E+01	7.058E+01	1.078E+02	1.912E+02	2.027E+02	1.240E+02	7.797E+01
	Rank	9	8	5	3	2	7	10	6	4	1
F17	mean	2.812E+02	1.932E+02	3.001E+02	2.417E+02	1.663E+02	2.639E+02	2.404E+02	2.334E+02	2.117E+02	1.511E+02
	std.	6.842E+01	1.022E+02	4.652E+01	1.212E+02	1.345E+01	1.708E+02	1.690E+02	8.678E+00	1.541E+01	4.484E+01
	best	2.388E+02	1.267E+02	2.574E+02	1.413E+02	1.508E+02	1.399E+02	1.323E+02	2.262E+02	1.964E+02	1.198E+02
	Rank	9	3	10	7	2	8	6	5	4	1

(continued on next page)

Table 2 (continued)

F	AL	PSOFIPS	PSOFDR	CLPSO	JDE	SaDE	TLBO	ETLBO	DGTLBO	BSA	LBSA
F18	mean	8.323E+02	9.388E+02	9.098E+02	8.178E+02	9.116E+02	9.148E+02	8.771E+02	9.938E+02	9.153E+02	9.186E+02
	std.	1.686E+00	2.396E+01	7.681E-01	1.053E+00	4.342E-01	4.459E+00	6.679E+01	1.333E+01	3.761E+00	6.806E+00
	best	8.310E+02	9.187E+02	9.090E+02	8.167E+02	9.111E+02	9.105E+02	8.000E+02	9.830E+02	9.119E+02	9.108E+02
	Rank	2	9	4	1	5	6	3	10	7	8
F19	mean	8.323E+02	9.449E+02	9.100E+02	8.180E+02	8.741E+02	9.594E+02	9.289E+02	9.803E+02	9.161E+02	9.137E+02
	std.	4.396E-01	2.678E+01	4.197E-01	4.957E-01	6.415E+01	5.067E+01	2.414E+01	3.604E+01	2.038E+00	1.897E-01
	best	8.318E+02	9.172E+02	9.096E+02	8.175E+02	8.000E+02	9.201E+02	9.093E+02	9.551E+02	9.147E+02	9.136E+02
	Rank	2	8	4	1	3	9	7	10	6	5
F20	mean	8.321E+02	9.501E+02	9.088E+02	8.172E+02	8.737E+02	9.475E+02	9.216E+02	1.016E+03	9.149E+02	8.779E+02
	std.	9.107E-01	2.351E+01	9.501E-01	4.755E-01	6.383E+01	3.759E+01	8.330E+00	3.126E+01	2.841E+00	6.752E+01
	best	8.310E+02	9.327E+02	9.078E+02	8.168E+02	8.000E+02	9.141E+02	9.136E+02	9.804E+02	9.128E+02	8.000E+02
	Rank	2	9	5	1	3	8	7	10	6	4
F21	mean	5.000E+02	9.728E+02	6.508E+02	8.604E+02	5.000E+02	9.551E+02	5.000E+02	9.694E+02	5.000E+02	5.000E+02
	std.	3.922E-06	1.750E+02	1.376E+02	1.503E+00	0.000E+00	3.941E+02	8.247E-13	4.062E+02	1.842E-13	1.969E-13
	best	5.000E+02	8.549E+02	5.427E+02	8.588E+02	5.000E+02	5.000E+02	5.000E+02	5.005E+02	5.000E+02	5.000E+02
	Rank	1	6	2	3	1	4	1	5	1	1
F22	mean	5.290E+02	8.860E+02	9.189E+02	5.004E+02	9.275E+02	9.220E+02	9.094E+02	1.055E+03	9.709E+02	9.372E+02
	std.	2.608E-01	2.439E+01	2.153E+01	4.134E-01	4.853E+00	3.630E+01	3.054E+01	8.101E+01	8.997E+00	1.765E+01
	best	5.287E+02	8.648E+02	8.984E+02	5.000E+02	9.230E+02	8.831E+02	8.747E+02	9.689E+02	9.617E+02	9.266E+02
	Rank	2	3	5	1	7	6	4	10	9	8
F23	mean	5.342E+02	1.030E+03	6.655E+02	8.668E+02	5.342E+02	1.052E+03	1.226E+03	8.292E+02	5.342E+02	5.342E+02
	std.	2.583E-04	1.329E+02	5.669E+01	1.596E-01	1.186E-04	2.102E+02	3.965E+01	1.592E+02	1.987E-05	4.661E-04
	best	5.342E+02	8.767E+02	6.255E+02	8.667E+02	5.342E+02	8.094E+02	1.184E+03	6.727E+02	5.342E+02	5.342E+02
	Rank	1	5	2	4	1	6	7	3	1	1
F24	mean	2.183E+02	9.579E+02	9.489E+02	2.126E+02	2.000E+02	2.000E+02	2.000E+02	8.476E+02	2.000E+02	2.000E+02
	std.	9.720E-01	2.510E+01	1.994E+00	1.237E+00	3.481E-14	4.702E-11	3.212E-12	5.342E+02	1.879E-12	0.000E+00
	best	2.176E+02	9.399E+02	9.471E+02	2.113E+02	2.000E+02	2.000E+02	2.000E+02	2.482E+02	2.000E+02	2.000E+02
	Rank	3	6	5	2	1	1	1	4	1	1
F25	mean	2.070E+02	1.064E+03	1.008E+03	2.120E+02	9.951E+02	1.006E+03	1.052E+03	1.211E+03	1.016E+03	9.938E+02
	std.	1.213E+01	2.582E+01	1.268E+01	1.878E+00	4.148E+00	2.774E+01	4.316E+01	1.059E+02	8.040E+00	1.593E+00
	best	2.000E+02	1.036E+03	1.000E+03	2.103E+02	9.924E+02	9.817E+02	1.009E+03	1.089E+03	1.007E+03	9.922E+02
	Rank	1	9	6	2	4	5	8	10	7	3
Average rank		4.72	6.12	5.64	3.08	3.56	5.80	5.24	6.84	5.20	3.20

5.3.3 مقایسه آزمون T برای 30D در CEC2005

تفاوت های بین LBSA و دیگر الگوریتم ها با استفاده از آزمون t مورد آزمایش قرار گرفتند [42]. قبل از آزمون t، یک آزمون t برای آزمایش برابری واریانس بین LBSA و دیگر الگوریتم ها استفاده شده است. مقادیر F بین LBSA و دیگر الگوریتم ها در جدول 3 نشان داده شده است. جدول 3 نشان می دهد که تفاوت های واریانس بین LBSA و دیگر الگوریتم ها معنی دار نبودند. در آزمایش های آزمون t، آزمون دو دامنه ای (دو دنباله) با سطح معنی دار 0.05 در این مقابله انجام شده است و مقادیر t و مقادیر p برای هر جفت تابع در جدول 4 ذکر شده است. نتایج بهتر بین LBSA و الگوریتم های دیگر برای تفاوت توابع بصورت برجسته در شکل نشان داده شده اند. " B "، " W " و " S " نشان می دهند که LBSA به ترتیب بطور معنی داری بهتر از، تقریباً مشابه، یا بطور معنی داری بدتر از الگوریتم مقایسه شده عمل می کنند. جدول 4 نشان می دهد که متوسط نرخ بسیار عالی و خوب بین LBSA و دیگر الگوریتم ها برای توابع 30D در CEC2005 در شرایط آزمون t برابر با 72.22 درصد

توابع با توجه به 10 الگوریتم نبود. این جدول همچنین نشان می دهد که عملکرد BSA بنیادی توسط LBSA بهبود یافته است.

توابع با توجه به 10 الگوریتم نبود. این جدول همچنین نشان می دهد که عملکرد BSA بنیادی توسط LBSA بهبود یافته است.

بهبود یافته است.

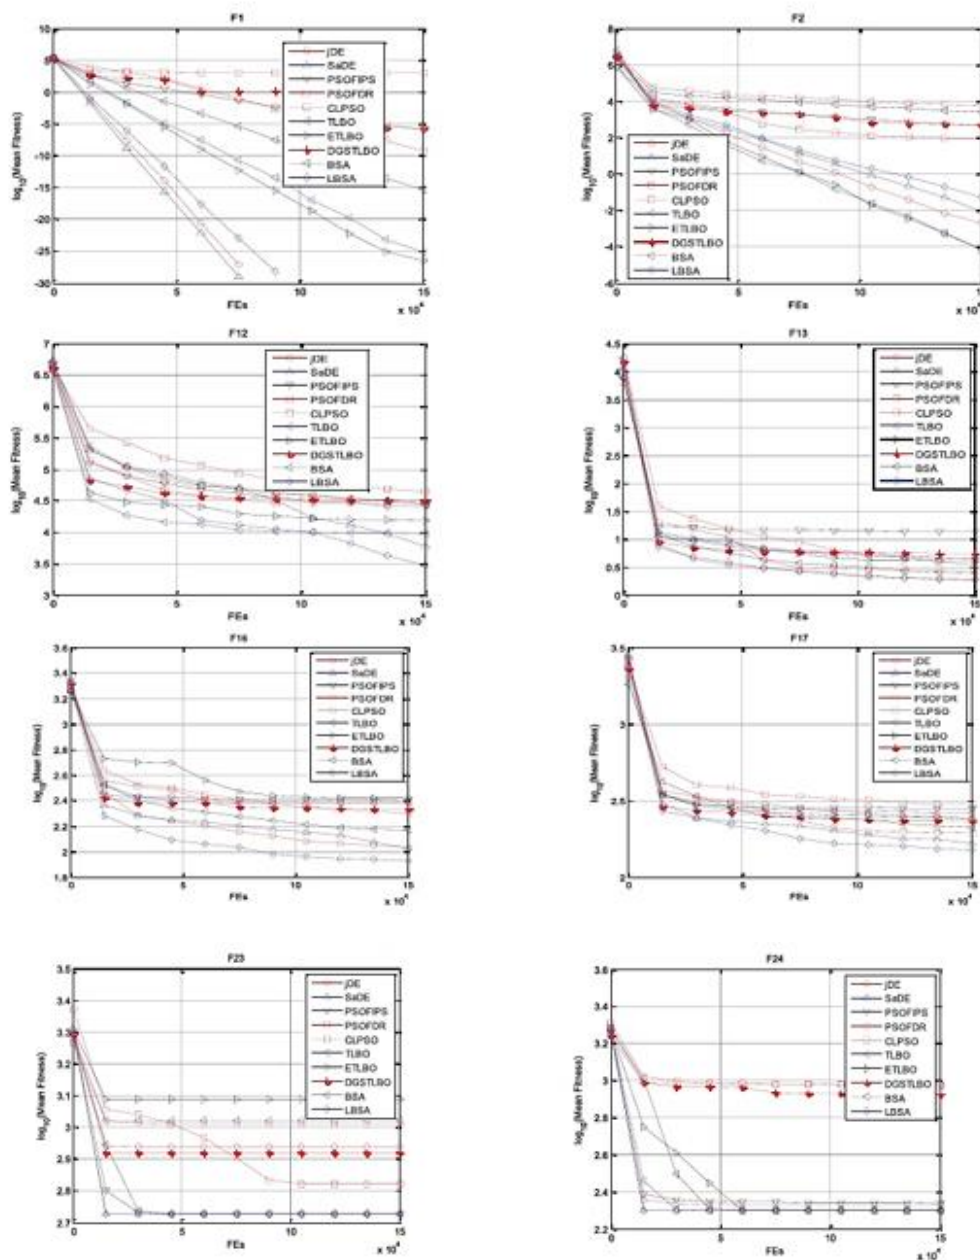


Fig. 3. The convergence graphs of eight respective functions.

5.4 آزمایشات برای توابع در CEC2014

CEC2014 شامل 30 تابع سنجشی می باشد. از آنجا که بهینه سازی سراسری خود را منتقل می کنند، پیدا کردن آنها نسبتاً دشوار است و راه حل های قابل قبول سخت برای بدست آوردن جواب دارند. در این بخش، تنها میانگین، انحراف معیار، بهترین راه حل ها و نتایج آزمون t حاصل از الگوریتم های مختلف داده می شود. در این بخش، تابع برازش خطای بین راه حل بهینه حقیقی و راه حل الگوریتم بهینه سازی است. فرض براین است که راه حل بهینه سراسری حقیقی X^* و بهترین راه حل به دست آمده توسط الگوریتم های بهینه سازی Y^* باشد. سپس،

$$|f(y^*) - f(x^*)|$$

برای تابع برازش انتخاب می شوند.

Table 3
Comparisons between LBSA and other algorithms using F-test for 30D functions of CEC2005.

F	jDE	SaDE	PSOwFIPS	PSOFDR	CLPSO	TLBO	ETLBO	DGSTLBO	BSA
F1	0.00E+00	0.00E+00	6.22E-48	2.50E-67	3.36E-41	8.70E-10	2.42E-07	4.38E-50	1.30E-29
F2	8.98E-03	1.37E-02	1.12E-06	6.31E-07	9.47E-09	9.96E-07	4.58E-06	1.30E-07	1.13E-07
F3	4.45E-02	3.23E-01	1.63E-01	4.89E-01	9.20E-03	4.09E-01	8.12E-01	1.62E-02	7.81E-01
F4	1.09E-03	4.67E-01	3.92E-01	4.33E-01	1.08E-01	4.25E-02	4.99E-01	7.11E-02	4.61E-01
F5	8.21E-01	2.12E-01	3.47E-02	3.41E-01	8.32E-01	2.71E-01	5.03E-01	4.27E-01	9.44E-02
F6	8.48E-01	5.46E-03	7.22E-03	5.11E-12	4.02E-01	8.61E-03	7.19E-01	2.77E-06	6.77E-01
F7	3.32E-17	1.00E+00	7.20E-21	4.54E-28	0.00E+00	0.00E+00	0.00E+00	2.72E-27	2.26E-07
F8	5.03E-01	3.60E-01	7.05E-02	3.90E-01	5.88E-01	1.62E-01	9.17E-01	8.73E-01	7.90E-01
F9	0.00E+00	2.55E-29	4.05E-32	2.68E-31	1.95E-22	1.76E-32	9.28E-33	3.37E-32	5.01E-30
F10	4.15E-01	5.89E-02	6.51E-01	2.76E-01	7.51E-01	6.45E-02	5.31E-01	9.52E-01	3.89E-01
F11	4.78E-01	9.94E-01	7.15E-01	5.29E-01	6.80E-01	2.28E-01	9.69E-01	7.03E-01	6.66E-01
F12	3.14E-01	5.49E-02	3.36E-02	1.73E-03	2.43E-01	1.97E-01	1.61E-02	1.22E-02	2.36E-02
F13	3.69E-02	6.23E-02	8.41E-01	4.51E-02	4.75E-01	9.33E-02	1.98E-02	9.89E-01	9.91E-01
F14	6.52E-01	6.52E-01	9.51E-01	5.12E-02	9.79E-01	8.38E-01	4.81E-01	1.10E-01	2.11E-01
F15	7.45E-01	3.93E-01	5.74E-01	4.62E-01	1.19E-01	9.49E-01	2.87E-01	3.04E-01	2.59E-02
F16	2.48E-02	6.83E-02	1.84E-02	6.18E-03	1.27E-01	1.24E-03	4.62E-03	3.75E-01	4.79E-02
F17	2.41E-01	1.65E-01	6.01E-01	3.23E-01	9.63E-01	1.29E-01	1.32E-01	7.22E-02	2.11E-01
F18	4.68E-02	8.11E-03	1.16E-01	1.49E-01	2.52E-02	6.01E-01	2.06E-02	4.14E-01	4.68E-01
F19	2.55E-01	1.75E-05	3.14E-01	1.00E-04	3.39E-01	2.80E-05	1.24E-04	5.54E-05	1.72E-02
F20	9.92E-05	9.44E-01	3.64E-04	2.16E-01	3.96E-04	4.73E-01	3.00E-02	3.53E-01	3.53E-03
F21	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
F22	1.10E-03	1.41E-01	4.37E-04	6.87E-01	8.04E-01	3.82E-01	5.01E-01	9.06E-02	4.12E-01
F23	1.71E-05	1.22E-01	4.70E-01	2.46E-11	1.35E-10	9.83E-12	2.76E-10	1.72E-11	3.63E-03
F24	1.58E-27	0.00E+00	2.57E-27	3.85E-30	6.09E-28	1.10E-06	1.97E-04	8.49E-33	8.16E-04
F25	8.37E-01	2.57E-01	3.39E-02	7.59E-03	3.11E-02	6.58E-03	2.72E-03	4.53E-04	7.56E-02

5.4.1 مقایسه درستی راه حل تابع 10D در CEC2014

نتایج آماری در شرایط میانگین، انحراف معیار، بهترین راه حل، رتبه باتوجه به میانگین و متوسط رتبه الگوریتم های مختلف برای توابع 30D در CEC2014 در جدول 5 ذکر شده است. بهترین نتایج به صورت برجسته نشان داده

شده اند. جدول 5 نشان می دهد که LBSA بهترین عملکرد را در شرایط میانگین برای توابع F26، F30، F34، F36، F37، F39، F41، و F47 دارد. jDE بهترین عملکرد را در شرایط میانگین برای توابع F28، F29، F33، F35، F45، F48، F50، F53 و F55 دارد. عملکرد در شرایط میانگین با SaDE نسبت به دیگر الگوریتم ها برای توابع F27، F31، F32، F42، F43، F44، F46 و F52 بهتر بود. برای تابع F38، BSA کوچکترین میانگین در بین تمام الگوریتم ها را دارا بود. برای تابع F40، میانگین FDRPSO کوچکترین بود. سه TLBO همان میانگین برای تابع F49 است که کوچکترین در 10 الگوریتم بود. برای تابع F54، PSOFIPS بهترین عملکرد در شرایط میانگین را دارد. باتوجه به بهترین راه حل ها، LBSA عملکرد بهتری نسبت به دیگر الگوریتم ها برای توابع F26، F29، F30، F34، F37، F41 و F42 دارد. jDE بهترین عملکرد برای 11 تابع (F27، F28، F33، F35، F43، F45، F48، F50، F51، F53 و F55) دارد و عملکرد در شرایط بهترین راه حل SaDE نسبت به دیگر الگوریتم ها برای توابع F27، F28، F31، F32، F42، F46 و F51 بهتر بود. PSOFIPS نسبت به دیگر الگوریتم ها در شرایط بهترین راه حل برای توابع F48، F51 و F54 بهتر است. PSOFDR عملکرد بهتری نسبت به دیگر الگوریتم ها برای توابع F26، F41، F42، F44 و F51 دارد. این جدول همچنین رتبه را باتوجه به میانگین 10 الگوریتم برای 30 تابع نشان می دهد. LBSA برای 9 تابع، jDE برای 10 تابع و SaDE برای 9 تابع در مکان اول رتبه بندی شده اند. متوسط رتبه jDE و LBSA مشابه هم بودند. رتبه الگوریتم های دیگر نسبتاً پایین تر از این سه الگوریتم بود.

5.4.2 مقایسه آزمون t برای توابع در CEC2014

نتایج آزمون t برای CEC2014 بین LBSO و دیگر الگوریتم ها در جدول 6 ذکر شده است، که نشان می دهد متوسط نرخ بسیار عالی و خوب بین LBSA و دیگر الگوریتم ها برای توابع 30D از CEC2014 در شرایط آزمون t برابر با 82.96 درصد $(\sum_{i=1}^9 (B_i + S_i) / 30 * 9)$ بود. جدول همچنین نشان می دهد که متوسط عملکرد LBSA خوب بود و عملکرد BSA بنیادی بهبود یافته است.

6. آموزش شبکه عصبی مصنوعی

شناسایی سیستم روشی برای شناسایی یا اندازه گیری مدل ریاضی یک سیستم از اندازه گیری های ورودی و خروجی سیستم است. بدست آوردن مدل دقیق ریاضی از یک سیستم غیرخطی گاهی اوقات دشوار است و از این رو ایجاد یک مدل هوشمند بسیار مهم است. روش های پیش بینی "L گام به جلو" از حالات زودتر $x(t-d+1), x(t-d+2), \dots, x(t)$ برای پیش بینی حالت $\hat{x}(t+L)$ استفاده می کند. می توان آن را به شرح زیر بیان کرد:

$$\hat{x}(t+L) = f(x(t-d+1), x(t-d+2), \dots, x(t-d+k), \dots, x(t)) \quad (16)$$

که در آن d تعداد متغیرهای ورودی یا بعد می باشد و L تعداد مراحل روبه جلو در مدل پیش بینی مستقیم "چند گام به جلو" است. یک ANN ساختار ریاضی انعطاف پذیری دارد که می تواند برای شناسایی سیستم های غیرخطی و پیش بینی سری های زمانی آشوبی استفاده شود. تکنیک بهینه سازی قدرتمند ممکن است به ANN کمک کند تا پارامترهای بهینه برای مسائل چند مدی و ابعاد بالا را پیدا کند. به نوبه خود، آموزش پارامترهای ANN معمولاً به منظور آزمایش اثر الگوریتم بهینه سازی انجام می شود. برای آزمایش اثر LBSA، سه شبکه عصبی پیشرو (feed-forward) برای شناسایی سیستم غیرخطی و پیش بینی سری های زمانی آشوبی به عنوان اهداف یادگیری انتخاب شدند. سه لایه ANN ($n \times p \times q$) در شکل 4 نشان داده شده است.

در شکل 4، a ، b و c واحدهای تغذیه یا بایاس هستند؛ وزن بین لایه ورودی و لایه پنهان است W_{ij} ، $i = 1, 2, 3, \dots, n$ و $j = 1, 2, 3, \dots, p$ ؛ و وزن بین لایه پنهان و لایه خروجی می باشد W_{jk} ، $k = 1, 2, 3, \dots, q$.

Table 4
Comparison between LBSA and other algorithms using t-test for 30D functions in CEC2005.

F	AL	jDE	SaDE	PSOwFIPS	PSOFDR	CLPSO	TLBO	ETLBO	DCSTLBO	BSA
F1	T	0.00000	0.00000	17.68471	3.33398	18.80463	11.54607	10.34528	3.16228	9.65364
	P	0.00000	0.00000	0.00000	0.00150	0.00000	0.00000	0.00000	0.00249	0.00000
F2	T	-5.40719	-4.63710	38.44279	5.94088	49.37527	-5.63054	-5.63149	15.05782	71.08136
	P	0.00000	0.00002	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F3	T	-4.68677	-6.98513	52.63073	6.46872	50.30775	2.98004	4.93468	6.85918	26.30395
	P	0.00000	0.00000	0.00000	0.00000	0.00000	0.00421	0.00001	0.00000	0.00000
F4	T	-8.83578	-1.43331	13.02394	0.23750	45.62547	2.63607	0.96386	3.34643	53.21922
	P	0.00000	0.15714	0.00000	0.81311	0.00000	0.01074	0.33912	0.00144	0.00000
F5	T	-4.24931	-3.92747	0.51187	8.91373	5.72179	9.73227	6.75718	21.69149	2.05247
	P	0.00008	0.00023	0.61069	0.00000	0.00000	0.00000	0.00000	0.00000	0.04465
F6	T	2.36387	6.27131	-0.08681	3.38988	1.17613	-0.85451	0.97110	3.29211	5.10191
	P	0.02146	0.00000	0.93112	0.00126	0.24435	0.39634	0.33553	0.00170	0.00000
F7	T	-18,101,746.42079	23.27015	-266,644.09865	3.16228	-12.64911	-2.23607	-5.47723	-131.68793	12.63842
	P	0.00000	0.00000	0.00000	0.00249	0.00000	0.02921	0.00000	0.00000	0.00000
F8	T	1.64038	0.53111	-3.44622	-3.90129	-1.76397	1.59020	-4.98949	-0.57250	1.47252
	P	0.10634	0.59737	0.00106	0.00025	0.08300	0.11723	0.00001	0.56920	0.14629
F9	T	-3.16228	3.16228	22.43949	50.46114	13.39723	24.10822	11.94422	31.95200	9.62749
	P	0.00249	0.00249	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F10	T	-13.44492	0.00782	60.89409	9.24016	48.58806	1.63538	7.24567	3.57657	0.99441
	P	0.00000	0.99379	0.00000	0.00000	0.00000	0.10739	0.00000	0.00071	0.32415
F11	T	7.71623	3.79701	0.89863	-17.27548	-0.93886	6.98202	20.60879	-7.48811	4.85430
	P	0.00000	0.00035	0.37257	0.00000	0.35170	0.00000	0.00000	0.00000	0.00001
F12	T	46.90837	2.18136	12.50062	3.25139	61.33180	8.77446	4.81014	9.66598	11.62215
	P	0.00000	0.03322	0.00000	0.00192	0.00000	0.00000	0.00001	0.00000	0.00000
F13	T	1.24288	23.38608	405.50792	6.75056	33.84927	23.61371	9.87963	117.49133	20.72818
	P	0.21891	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F14	T	18.49545	5.69450	-1.89436	-6.87122	8.15495	1.03281	8.61714	-0.56327	3.17343
	P	0.00000	0.00000	0.06317	0.00000	0.00000	0.30598	0.00000	0.57542	0.00241
F15	T	-9.99534	-3.98428	-2.14955	6.02115	-14.69182	2.73337	3.65687	0.44053	-17.75187
	P	0.00000	0.00019	0.03577	0.00000	0.00000	0.00830	0.00055	0.66119	0.00000
F16	T	2.50162	3.67786	15.42945	8.43688	28.59267	3.75187	8.40948	55.11609	9.57010
	P	0.01521	0.00052	0.00000	0.00000	0.00000	0.00041	0.00000	0.00000	0.00000
F17	T	3.83912	1.77984	8.70942	2.06396	12.63384	3.49691	2.79639	9.86821	6.99704
	P	0.00031	0.08034	0.00000	0.04350	0.00000	0.00091	0.00700	0.00000	0.00000
F18	T	-80.19478	-5.63544	-67.42664	4.42834	-7.01082	-2.56462	-3.38845	27.51971	-2.36599
	P	0.00000	0.00000	0.00000	0.00004	0.00000	0.01294	0.00127	0.00000	0.02134
F19	T	-987.60043	-3.38841	-932.07451	6.37335	-44.16027	4.92961	3.43036	10.11533	6.28060
	P	0.00000	0.00127	0.00000	0.00000	0.00000	0.00001	0.00112	0.00000	0.00000
F20	T	-4.91949	-0.24609	-3.71294	5.53261	2.51308	4.93922	3.52358	10.19886	3.00469
	P	0.00001	0.80648	0.00046	0.00000	0.01477	0.00001	0.00084	0.00000	0.00392
F21	T	1313.62799	-4.74342	3.56127	14.79979	6.00513	6.32393	10.28143	6.32969	17.32051
	P	0.00000	0.00001	0.00075	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F22	T	-135.50194	-2.90207	-126.65053	-9.31134	-3.59045	-2.06451	-4.31748	7.79198	9.33451
	P	0.00000	0.00523	0.00000	0.00000	0.00068	0.04345	0.00006	0.00000	0.00000
F23	T	11,414.66588	-2.88386	-1.14256	20.43957	12.69206	13.49374	95.50230	10.15204	-3.55380
	P	0.00000	0.00550	0.25792	0.00000	0.00000	0.00000	0.00000	0.00000	0.00076
F24	T	55.94285	-482.99068	103.24512	165.41374	2056.93066	9.99764	10.95402	6.63985	3.31402
	P	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00159
F25	T	-1738.64382	1.69241	-352.23753	14.86674	6.04790	2.31739	7.38330	11.25121	15.09965
	P	0.00000	0.09593	0.00000	0.00000	0.00000	0.02403	0.00000	0.00000	0.00000
B		9	8	12	20	17	17	18	20	20
W		13	10	8	4	5	4	5	2	3
S		3	7	5	1	3	4	2	3	2




Fig. 4. Structure of a three layers feed forward neural network.

Table 5
Comparative results of ten algorithms for 30D functions in CEC2014.

F	AL	PSOFIPS	PSOFDR	CLPSO	jDE	SaDE	TLBO	ETLBO	DGSLBO	BSA	LBSA
F26	mean	1.02E+07	2.78E+06	2.92E+07	3.37E+05	4.41E+05	8.28E+05	3.33E+05	1.04E+07	5.12E+06	2.79E+05
	std.	2.88E+06	1.98E+06	4.33E+06	2.98E+05	3.04E+05	7.89E+05	2.02E+05	8.61E+06	4.10E+06	1.65E+05
	best	5.60E+06	1.32E+05	2.14E+07	1.06E+05	1.23E+05	5.77E+04	1.37E+05	3.15E+06	4.46E+05	7.85E+04
	Rank	8	6	10	3	4	5	2	9	7	1
F27	mean	1.13E+04	1.53E+08	1.26E+03	1.99E-14	2.84E-15	1.44E+02	1.19E+02	4.59E+06	8.34E-01	4.83E-14
	std.	5.27E+03	3.61E+08	7.40E+02	1.37E-14	8.99E-15	1.72E+02	1.56E+02	1.11E+07	1.48E+00	1.92E-14
	best	3.63E+03	4.60E+01	2.76E+02	0.00E+00	0.00E+00	2.82E+01	3.29E-01	1.48E+03	5.38E-02	2.84E-14
	Rank	8	10	7	2	1	6	5	9	4	3
F28	mean	6.94E+03	5.40E+02	7.67E+02	4.55E-14	4.30E-12	2.39E+03	2.14E+03	1.44E+01	5.74E-04	2.27E-13
	std.	5.03E+03	6.05E+02	1.20E+03	2.40E-14	1.25E-11	1.77E+03	1.02E+03	1.68E+01	9.44E-04	1.00E-13
	best	1.32E+03	1.36E+01	5.76E+01	0.00E+00	0.00E+00	2.90E+02	5.59E+02	6.71E-01	3.13E-05	1.14E-13
	Rank	10	6	7	1	3	9	8	5	4	2
F29	mean	2.67E+01	9.50E+01	1.16E+02	2.49E+01	8.29E+01	9.70E+01	7.53E+01	1.46E+02	9.83E+01	4.23E+01
	std.	6.37E-01	3.24E+01	1.33E+01	1.74E+01	2.70E+01	3.36E+01	5.88E+00	3.78E+01	2.96E+01	3.57E+01
	best	2.53E+01	6.66E+01	9.56E+01	1.81E+01	6.73E+01	6.74E+01	6.79E+01	8.79E+01	6.81E+01	1.73E-03
	Rank	2	6	9	5	7	4	10	8	3	1
F30	mean	2.10E+01	2.09E+01	2.05E+01	2.04E+01	2.06E+01	2.10E+01	2.09E+01	2.10E+01	2.04E+01	2.03E+01
	std.	5.71E-02	1.22E-01	4.58E-02	3.56E-02	5.89E-02	5.23E-02	7.24E-02	4.34E-02	1.56E-02	3.42E-02
	best	2.09E+01	2.06E+01	2.04E+01	2.03E+01	2.05E+01	2.09E+01	2.08E+01	2.09E+01	2.03E+01	2.03E+01
	Rank	6	5	3	2	4	6	5	6	2	1
F31	mean	6.19E+00	7.67E+00	1.70E+01	1.48E+01	2.61E-01	1.54E+01	1.59E+01	1.67E+01	1.62E+01	8.37E+00
	std.	2.22E+00	1.98E+00	6.10E-01	3.97E+00	4.92E-01	2.14E+00	2.75E+00	3.45E+00	9.69E-01	3.22E+00
	best	2.75E+00	4.63E+00	1.60E+01	4.01E+00	0.00E+00	1.17E+01	1.01E+01	1.23E+01	1.47E+01	5.25E+00
	Rank	2	3	10	5	1	6	7	9	8	4
F32	mean	2.56E-03	1.33E+01	3.92E-03	1.71E-13	0.00E+00	6.74E-02	2.75E-02	1.01E+00	4.19E-03	5.41E-03
	std.	6.75E-03	1.31E+01	1.61E-03	8.04E-14	0.00E+00	8.69E-02	2.23E-02	1.50E+00	1.32E-02	8.26E-03
	best	7.08E-05	1.48E-02	1.37E-03	1.14E-13	0.00E+00	7.84E-12	1.02E-12	1.20E-01	6.62E-07	1.14E-13
	Rank	3	10	4	2	1	8	7	9	5	6
F33	mean	6.60E+01	3.48E+01	5.86E-01	1.14E-14	1.99E-01	7.37E+01	8.00E+01	7.67E+01	2.93E+00	1.14E-13
	std.	1.22E+01	5.70E+00	6.20E-01	3.60E-14	4.20E-01	2.11E+01	1.88E+01	2.45E+01	1.46E+00	0.00E+00
	best	4.32E+01	2.19E+01	2.65E-04	0.00E+00	0.00E+00	5.07E+01	4.48E+01	3.48E+01	1.14E+00	1.14E-13
	Rank	7	6	4	1	3	8	10	9	5	2
F34	mean	1.53E+02	5.53E+01	7.79E+01	5.82E+01	7.70E+01	7.68E+01	8.00E+01	9.84E+01	5.95E+01	4.32E+01
	std.	1.61E+01	1.54E+01	1.49E+01	7.79E+00	1.68E+01	1.08E+01	1.42E+01	3.08E+01	7.94E+00	7.61E+00
	best	1.21E+02	3.51E+01	5.52E+01	4.78E+01	4.47E+01	5.87E+01	5.87E+01	6.41E+01	4.56E+01	2.70E+01
	Rank	10	2	7	3	6	5	8	9	4	1
F35	mean	1.87E+03	9.70E+02	2.50E+01	1.69E-01	2.56E+00	1.72E+03	1.57E+03	2.39E+03	3.22E+01	1.08E+01
	std.	4.44E+02	3.47E+02	5.21E+00	5.12E-01	4.09E+00	7.41E+02	4.26E+02	4.71E+02	6.57E+00	5.07E+00
	best	1.35E+03	3.70E+02	1.83E+01	0.00E+00	3.39E-02	4.64E+02	9.52E+02	1.59E+03	2.15E+01	5.12E+00
	Rank	8	9	10	1	2	7	6	5	3	4
F36	mean	5.76E+03	3.08E+03	3.24E+03	2.88E+03	4.11E+03	6.71E+03	6.46E+03	3.39E+03	2.56E+03	2.31E+03
	std.	3.43E+02	6.19E+02	2.18E+02	3.06E+02	4.80E+02	3.92E+02	4.46E+02	5.45E+02	2.56E+02	3.17E+02
	best	5.23E+03	1.77E+03	2.98E+03	2.51E+03	3.18E+03	6.01E+03	5.52E+03	2.42E+03	2.12E+03	1.86E+03
	Rank	8	4	5	3	7	10	9	6	2	1
F37	mean	2.62E+00	8.12E-01	5.42E-01	4.96E-01	1.05E+00	2.64E+00	2.60E+00	2.75E+00	4.37E-01	4.18E-01
	std.	2.82E-01	6.51E-01	8.53E-02	5.71E-02	1.24E-01	2.47E-01	3.32E-01	2.62E-01	7.85E-02	5.15E-02
	best	1.97E+00	3.12E-01	4.12E-01	3.72E-01	7.98E-01	2.13E+00	1.93E+00	2.48E+00	3.05E-01	3.62E-01
	Rank	8	5	4	3	6	9	7	10	2	1
F38	mean	3.46E-01	4.35E-01	4.18E-01	3.10E-01	3.09E-01	4.88E-01	4.11E-01	4.71E-01	2.84E-01	2.90E-01
	std.	3.30E-02	1.07E-01	7.14E-02	4.77E-02	3.58E-02	1.14E-01	6.86E-02	1.13E-01	4.68E-02	4.34E-02
	best	2.89E-01	2.55E-01	2.77E-01	2.58E-01	2.62E-01	3.50E-01	2.97E-01	3.09E-01	2.06E-01	2.10E-01
	Rank	5	8	7	4	3	10	6	9	1	2
F39	mean	3.07E-01	8.91E-01	3.44E-01	2.95E-01	2.81E-01	2.88E-01	2.78E-01	2.88E-01	2.45E-01	2.30E-01
	std.	3.63E-02	3.59E-01	3.38E-02	2.67E-02	2.64E-02	4.70E-02	4.42E-02	4.92E-02	4.02E-02	2.69E-02
	best	2.54E-01	1.88E-01	2.97E-01	2.56E-01	2.25E-01	2.11E-01	1.84E-01	2.26E-01	2.03E-01	1.87E-01
	Rank	7	9	8	6	4	5	3	5	2	1
F40	mean	1.58E+01	4.49E+00	1.09E+01	5.81E+00	9.71E+00	1.80E+01	1.89E+01	3.75E+01	7.06E+00	5.93E+00
	std.	9.26E-01	6.87E-01	9.63E-01	8.14E-01	1.28E+00	5.93E+00	8.66E+00	2.19E+01	1.07E+00	1.22E+00
	best	1.41E+01	3.18E+00	9.09E+00	4.24E+00	7.32E+00	1.03E+01	9.75E+00	1.54E+01	5.16E+00	3.87E+00
	Rank	7	1	6	2	5	8	9	10	4	3
F41	mean	1.18E+01	1.05E+01	1.11E+01	1.06E+01	1.15E+01	1.20E+01	1.19E+01	1.11E+01	1.07E+01	1.02E+01
	std.	2.50E-01	8.64E-01	2.31E-01	1.90E-01	2.07E-01	4.35E-01	3.94E-01	6.62E-01	2.71E-01	4.55E-01
	best	1.13E+01	8.55E+00	1.07E+01	1.03E+01	1.13E+01	1.14E+01	1.14E+01	1.01E+01	1.01E+01	9.37E+00
	Rank	7	2	5	3	6	9	8	5	4	1
F42	mean	3.76E+05	1.36E+05	2.07E+06	3.16E+04	1.33E+04	1.91E+05	2.11E+05	1.67E+05	1.54E+05	4.42E+04
	std.	1.12E+05	1.04E+05	6.62E+05	3.34E+04	6.50E+03	1.73E+05	9.21E+04	2.13E+05	8.75E+04	3.70E+04
	best	2.44E+05	2.69E+04	1.07E+06	2.49E+03	1.73E+03	3.29E+04	8.02E+04	3.54E+04	4.92E+04	8.62E+03
	Rank	9	4	10	2	1	7	8	6	5	3

(continued on next page)

Table 5 (continued)

F	AL	PSOFIPS	PSOFDR	CLPSO	jDE	SaDE	TLBO	ETLBO	DGSTLBO	BSA	LBSA
F43	mean	1.59E+03	3.38E+03	4.92E+02	2.63E+02	6.89E+01	2.93E+03	3.31E+03	8.71E+02	9.10E+02	1.14E+03
	std.	8.50E+02	4.21E+03	9.30E+01	5.11E+02	3.43E+01	2.35E+03	4.11E+03	1.02E+03	1.05E+03	1.29E+03
	best	4.78E+02	3.13E+02	3.44E+02	1.35E+01	3.09E+01	1.35E+02	1.64E+02	6.17E+01	4.35E+01	6.23E+01
	Rank	7	10	3	2	1	8	9	4	5	6
F44	mean	1.19E+01	1.57E+01	1.01E+01	1.41E+01	5.55E+00	2.12E+01	2.12E+01	2.71E+01	6.91E+00	6.31E+00
	std.	8.29E-01	2.33E+01	1.02E+00	1.13E+00	6.59E-01	2.55E+01	2.54E+01	2.86E+01	6.25E-01	1.01E+00
	best	1.01E+01	4.44E+00	8.20E+00	1.19E+01	4.74E+00	5.77E+00	6.72E+00	9.65E+00	6.06E+00	4.60E+00
	Rank	5	7	4	6	1	8	8	9	3	2
F45	mean	5.81E+03	7.05E+03	5.95E+03	3.17E+01	4.31E+01	1.54E+03	1.44E+03	4.28E+02	1.68E+02	9.02E+01
	std.	2.71E+03	1.27E+04	3.35E+03	3.78E+01	2.96E+01	9.69E+02	6.69E+02	1.77E+02	1.91E+02	8.20E+01
	best	2.36E+03	1.37E+03	2.48E+03	1.08E+01	1.91E+01	6.68E+02	3.41E+02	2.03E+02	2.75E+01	3.06E+01
	Rank	8	10	9	1	2	7	6	5	4	3
F46	mean	1.49E+05	6.77E+04	3.39E+05	3.66E+03	2.49E+03	9.72E+04	1.19E+05	2.20E+04	6.20E+03	9.86E+03
	std.	6.40E+04	4.21E+04	1.22E+05	3.15E+03	2.80E+03	9.01E+04	1.00E+05	2.22E+04	3.02E+03	1.32E+04
	best	8.47E+04	8.85E+03	1.25E+05	6.53E+02	2.21E+02	1.89E+04	3.16E+04	4.09E+03	2.22E+03	1.22E+03
	Rank	9	6	10	2	1	7	8	5	3	4
F47	mean	2.25E+02	2.27E+02	2.70E+02	2.96E+02	1.36E+02	2.81E+02	3.27E+02	3.14E+02	1.79E+02	1.14E+02
	std.	7.27E+01	9.97E+01	5.98E+01	8.12E+01	7.92E+01	1.08E+02	1.33E+02	1.41E+02	8.11E+01	7.56E+01
	best	1.67E+02	1.44E+02	1.59E+02	9.35E+01	2.51E+01	1.64E+02	5.82E+01	1.49E+02	5.06E+01	2.41E+01
	Rank	4	5	6	8	2	7	10	9	3	1
F48	mean	3.14E+02	3.18E+02	3.15E+02	3.14E+02	3.15E+02	3.15E+02	3.15E+02	3.15E+02	3.15E+02	3.15E+02
	std.	1.57E-04	3.50E+00	2.29E-01	2.89E-13	0.00E+00	1.23E-11	1.78E-10	4.43E-01	2.92E-07	1.44E-13
	best	3.14E+02	3.15E+02	3.15E+02	3.14E+02	3.15E+02	3.15E+02	3.15E+02	3.15E+02	3.15E+02	3.15E+02
	Rank	1	3	2	1	2	2	2	2	2	2
F49	mean	2.24E+02	2.27E+02	2.27E+02	2.27E+02	2.25E+02	2.00E+02	2.00E+02	2.00E+02	2.27E+02	2.26E+02
	std.	5.46E-01	2.58E+00	1.01E+00	4.59E+00	5.21E-01	2.20E-03	2.19E-03	9.68E-04	2.42E+00	1.28E+00
	best	2.23E+02	2.23E+02	2.25E+02	2.24E+02	2.24E+02	2.00E+02	2.00E+02	2.00E+02	2.25E+02	2.24E+02
	Rank	2	5	5	5	3	1	1	1	5	4
F50	mean	2.07E+02	2.06E+02	2.10E+02	2.00E+02	2.06E+02	2.01E+02	2.00E+02	2.02E+02	2.07E+02	2.09E+02
	std.	2.45E+00	2.09E+00	1.62E+00	1.46E-01	2.49E+00	2.39E+00	5.33E-06	3.62E+00	6.48E-01	3.10E+00
	best	2.04E+02	2.04E+02	2.08E+02	2.00E+02	2.03E+02	2.00E+02	2.00E+02	2.00E+02	2.06E+02	2.04E+02
	Rank	5	4	7	1	4	2	1	3	5	6
F51	mean	1.70E+02	1.51E+02	1.00E+02	1.00E+02	1.00E+02	1.10E+02	1.00E+02	1.10E+02	1.00E+02	1.00E+02
	std.	4.83E+01	5.18E+01	3.00E-02	6.12E-02	7.09E-02	3.15E+01	1.57E-01	3.15E+01	5.83E-02	7.52E-02
	best	1.00E+02	1.00E+02	1.00E+02	1.00E+02	1.00E+02	1.00E+02	1.00E+02	1.00E+02	1.00E+02	1.00E+02
	Rank	4	3	1	1	1	2	1	2	1	1
F52	mean	4.34E+02	7.12E+02	4.38E+02	5.65E+02	3.62E+02	5.47E+02	6.56E+02	7.94E+02	4.09E+02	4.34E+02
	std.	3.50E+01	1.84E+02	1.33E+01	1.73E+02	5.04E+01	1.66E+02	2.13E+02	2.15E+02	3.71E+00	6.71E+01
	best	3.76E+02	4.02E+02	4.17E+02	4.01E+02	3.00E+02	4.02E+02	4.02E+02	4.06E+02	4.04E+02	3.71E+02
	Rank	3	8	4	6	1	5	7	9	2	3
F53	mean	3.98E+02	1.48E+03	9.21E+02	3.83E+02	8.51E+02	1.24E+03	1.18E+03	1.43E+03	8.77E+02	8.34E+02
	std.	1.16E+01	3.70E+02	3.47E+01	5.59E+00	2.76E+01	3.51E+02	2.30E+02	4.37E+02	1.66E+01	3.87E+01
	best	3.89E+02	1.02E+03	8.64E+02	3.76E+02	8.06E+02	9.20E+02	8.94E+02	9.96E+02	8.54E+02	7.87E+02
	Rank	2	10	6	1	4	8	7	9	5	3
F54	mean	2.14E+02	6.65E+06	3.11E+04	2.15E+02	9.67E+02	3.31E+06	3.93E+06	3.08E+06	1.41E+03	1.29E+03
	std.	1.02E+00	1.10E+07	1.52E+04	1.39E+00	1.47E+02	5.39E+06	5.14E+06	4.99E+06	1.89E+02	5.91E+02
	best	2.12E+02	2.17E+03	7.11E+03	2.13E+02	6.69E+02	1.25E+03	1.44E+03	9.91E+02	1.21E+03	7.75E+02
	Rank	1	10	6	2	3	8	9	7	5	4
F55	mean	7.00E+02	1.82E+04	7.94E+03	3.87E+02	1.15E+03	3.35E+03	3.37E+03	6.47E+03	2.55E+03	1.93E+03
	std.	8.54E+01	3.03E+04	2.72E+03	6.82E+01	5.64E+02	1.35E+03	1.75E+03	3.43E+03	7.49E+02	5.26E+02
	best	5.98E+02	1.78E+03	5.62E+03	2.92E+02	5.90E+02	1.62E+03	1.58E+03	3.37E+03	1.42E+03	1.15E+03
	Rank	2	10	9	1	3	6	7	8	5	4
Av. rank	5.63	6.13	6.07	2.70	3.00	6.57	6.30	6.97	4.00	2.70	

آموزش یک ANN به معنی بهینه سازی وزن و بایاس آن است. برای سه لایه ANN $(n \times p \times q)$ ، تعداد متغیرهایی که باید بهینه سازی شوند $(p + 1)q + (n + 1)p$ است و میانگین مجموع خطاهای مربع (MSE) در تمامی الگوهای آموزش اغلب به عنوان تابع هدف الگوریتم های بهینه سازی انتخاب می شود، محاسبه به شرح زیر می باشد:

$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n \frac{1}{2} (d_{ij} - y_{ij})^2 \quad (17)$$

که m اندازه داده های آموزش، n تعداد خروجی ها، d_{ij} خروجی موردنظر و y_{ij} خروجی ANN می باشد.

Table 6
Comparison between LBSA and other algorithms using a t-test for 30D functions in CEC2014.

F	AL	jDE	SaDE	PSOwFIPS	PSOFDR	CLPSO	TLBO	ETLBO	DGSLBO	BSA
F26	T	0.93373	2.56475	18.86069	6.88243	36.57498	3.72942	1.12409	6.44030	6.45541
	P	0.35431	0.01294	0.00000	0.00000	0.00000	0.00044	0.26561	0.00000	0.00000
F27	T	-6.59912	-11.75755	11.75633	2.32644	9.29153	4.56562	4.17978	2.26966	3.08124
	P	0.00000	0.00000	0.00000	0.02351	0.00000	0.00003	0.00010	0.02696	0.00315
F28	T	-9.66465	1.77922	7.55034	4.88356	3.50760	7.39477	11.46202	4.69504	3.32637
	P	0.00000	0.08044	0.00000	0.00001	0.00088	0.00000	0.00000	0.00002	0.00153
F29	T	-2.40107	4.96405	-2.39638	5.99467	10.63308	6.10876	4.99903	10.87966	6.61401
	P	0.01957	0.00001	0.01980	0.00000	0.00000	0.00000	0.00001	0.00000	0.00000
F30	T	5.39965	21.32020	55.64948	24.24835	14.66970	56.32828	43.73363	65.34210	7.15584
	P	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F31	T	6.84351	-13.62043	-3.05097	-1.01696	14.46031	9.92347	9.67976	9.66437	12.68247
	P	0.00000	0.00000	0.00344	0.31340	0.00000	0.00000	0.00000	0.00000	0.00000
F32	T	-3.58973	-3.58973	-1.46667	5.57656	-0.97108	3.88951	5.09523	3.66324	-0.43106
	P	0.00068	0.00068	0.14787	0.00000	0.33554	0.00026	0.00000	0.00000	0.66802
F33	T	-15.58846	2.59808	29.66300	33.38307	5.17855	19.13046	23.26561	17.11579	10.96053
	P	0.00000	0.01186	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F34	T	7.53203	10.03933	33.90337	3.84690	11.37620	13.92505	12.49798	9.52840	8.13697
	P	0.00000	0.00000	0.00000	0.00030	0.00000	0.00000	0.00000	0.00000	0.00000
F35	T	-11.39133	-6.89722	22.97610	15.14510	10.70980	12.63964	20.40669	27.63079	14.13708
	P	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F36	T	6.96727	17.03972	40.35873	5.99338	13.20624	47.68523	41.46806	9.33609	3.34007
	P	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00147
F37	T	5.61489	25.85856	42.18177	3.30937	6.81484	48.12225	35.62649	47.84830	1.11279
	P	0.00000	0.00000	0.00000	0.00161	0.00000	0.00000	0.00000	0.00000	0.27039
F38	T	1.69894	1.78434	5.59128	6.88176	8.33642	8.88374	8.12900	8.16238	-0.51924
	P	0.09469	0.07960	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.60557
F39	T	9.36429	7.37392	9.28330	10.05893	14.35105	5.84382	5.00058	5.60192	1.65264
	P	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00001	0.00000	0.10381
F40	T	-0.43678	11.69433	35.33066	-5.60942	17.46573	10.89866	8.13816	7.87328	3.83052
	P	0.66389	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00032
F41	T	4.35862	14.22154	16.74675	1.48492	9.80169	15.66797	14.96744	5.80590	4.72921
	P	0.00005	0.00000	0.00000	0.14298	0.00000	0.00000	0.00000	0.00000	0.00001
F42	T	-1.38252	-4.50767	15.43646	4.52930	16.69730	4.56234	9.21876	3.09944	6.34291
	P	0.17211	0.00003	0.00000	0.00003	0.00000	0.00003	0.00000	0.00299	0.00000
F43	T	-3.47194	-4.55733	1.60336	2.79230	-2.75394	3.65178	2.75586	-0.90215	-0.76350
	P	0.00098	0.00003	0.11429	0.00708	0.00785	0.00056	0.00781	0.37071	0.44826
F44	T	28.06442	-3.44540	23.40168	2.21312	14.57672	3.18891	3.21238	3.97707	2.74686
	P	0.00000	0.00107	0.00000	0.03084	0.00000	0.00230	0.00215	0.00020	0.00800
F45	T	-3.55284	-2.96160	11.57150	3.00856	9.59609	8.14252	10.92957	9.49231	2.05113
F46	T	-2.50497	-2.99652	11.65085	7.18729	14.61425	5.25779	5.87732	2.57563	-1.48264
	P	0.01508	0.00401	0.00000	0.00000	0.00000	0.00000	0.00000	0.01258	0.14358
F47	T	8.98665	1.10043	5.81391	4.96272	8.83864	6.94172	7.63707	6.84961	3.22617
	P	0.00000	0.27569	0.00000	0.00001	0.00000	0.00000	0.00000	0.00000	0.00206
F48	T	-2.08995E+13	-2.15758	-4.30336E+04	4.11727	3.21777	5.66938	2.21585	3.02585	4.40829
	P	0.00000	0.03511	0.00000	0.00012	0.00212	0.00000	0.03064	0.00369	0.00005
F49	T	1.96584	-4.13892	-6.95976	1.79700	4.52992	-109.24755	-109.25044	-109.27495	2.25320
	P	0.05411	0.00011	0.00000	0.07754	0.00003	0.00000	0.00000	0.00000	0.02804
F50	T	-14.24590	-3.54490	-1.84809	-3.64301	2.49945	-10.93030	-15.14135	-7.94073	-3.15544
	P	0.00000	0.00078	0.06969	0.00058	0.01529	0.00000	0.00000	0.00000	0.00254
F51	T	0.65422	0.50525	7.94725	5.35959	8.14779	1.75888	5.25514	1.76198	-0.41303
	P	0.51556	0.61530	0.00000	0.00000	0.00000	0.08387	0.00000	0.08334	0.68111
F52	T	3.85682	-4.72137	-0.02531	7.75919	0.29628	3.43129	5.45158	8.73187	-2.03530
	P	0.00029	0.00002	0.97989	0.00000	0.76807	0.00111	0.00000	0.00000	0.04640
F53	T	-63.20117	1.99838	-59.24825	9.51431	9.19405	6.24567	8.04197	7.39735	5.59681
	P	0.00000	0.05037	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
F54	T	-10.02046	-2.94965	-10.02816	3.30750	10.76868	3.35860	4.19197	3.77793	1.03517
	P	0.00000	0.00458	0.00000	0.00162	0.00000	0.00139	0.00010	0.00131	0.30489
F55	T	-15.96627	-5.53732	-12.67155	2.93465	11.88726	5.35552	4.30672	7.16346	3.69768
	P	0.00000	0.00000	0.00000	0.00478	0.00000	0.00000	0.00006	0.00000	0.00048
B		10	10	19	25	27	27	27	26	20
W		14	14	7	2	1	2	2	2	2
S		6	6	4	3	2	1	1	2	8

Table 7
Comparisons of five algorithms for SISO system over 30 runs.

merits	BSA	CLPSO	TLBO	jDE	LBSA
best	1.1248E-04	3.6081E-04	5.6342E-06	9.5704E-04	3.4287E-05
mean	2.6561E-04	1.5722E-03	1.1618E-03	1.6750E-03	2.5628E-04
Std.	1.1451E-04	1.6350E-03	9.0796E-04	3.4113E-04	2.7032E-04
MT(sec)	3.9780E+01	4.5516E+01	3.0174E+01	2.3340E+01	3.0302E+01
TStd.	3.4299E+00	1.8671E+00	5.4764E-01	6.0298E-01	1.0252E-01
SR	30	24	30	27	30

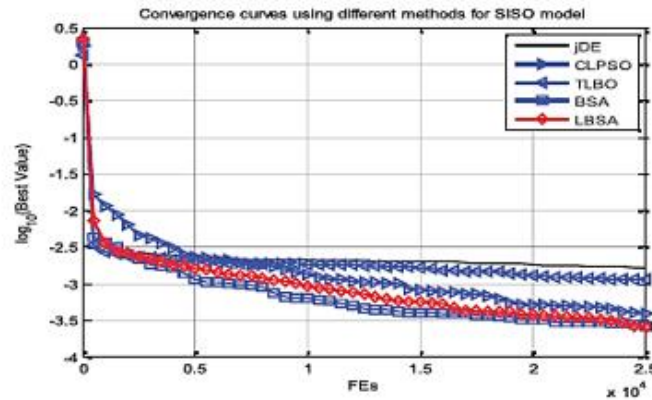


Fig. 5. The average fitness curves of five algorithms for SISO system.

6.1 شناسایی سیستم غیر خطی

A. سیستم غیر خطی SISO

سیستم غیر خطی SISO استفاده شده در این آزمایش به شرح زیر می باشد:

$$y = \sin(2x)e^{-2x} \quad (18)$$

در این آزمایش، اندازه شبکه $1 \times 5 \times 1$ بود و تعداد متغیرهایی که باید تعیین شوند 16 بود. علاوه بر این، 124 جفت از داده ها از معادله 18 به عنوان نمونه های آموزش انتخاب شده بود. نتایج به وضوح نشان می دهند، تنها 5 الگوریتم بهینه سازی برای بهینه سازی شبکه عصبی استفاده شده بود. اندازه جمعیت همه ی الگوریتم ها 50 بود، حداکثر F_E ، 25000 بود و دیگر پارامترهای الگوریتم های مختلف مشابه مورد CEC2005 استفاده شده است. جدول 7 نشان دهنده نتایج آموزش 5 الگوریتم برای اجرا شدن مستقل بیش از 30 بار می باشد. در اینجا، " بهترین مقدار MSE است و " میانگین " متوسط بهترین مقدار از MSE می باشد، " Std. " انحراف معیار بهترین راه حل است و " MT " میانگین زمان همگرایی الگوریتم برای یک راه حل قابل قبول است. اگر الگوریتم به راه حل بهینه در 30 بار اجرا شدن همگرا نشود، " MT " میانگین زمان الگوریتم است که توسط حداکثر F_E به پایان می رسد. علاوه بر این، " TStd. " انحراف معیار زمان است و " SR " نسبت موفق 30 بار اجرا شدن مستقل برنامه می باشد. راه حل قابل قبول 0.002 است. جدول نشان می دهد که بهترین و میانگین MSE از LBSA کوچکترین

بود و Std. در BSA کوچکترین مقدار از 5 الگوریتم بود. MT از jDE کوچکترین بود و Tstd. در LBSA کوچکترین بود. نسبت های موفق از 4 الگوریتم 100 درصد بود. فرآیند همگرایی با توجه به F_E در شکل 5 نشان داده شده است، که نشان می دهد سرعت همگرایی BSA نسبت به دیگر الگوریتم ها سریع تر بود و متوسط دقت همگرایی LBSA نسبت به دیگر الگوریتم ها بالاتر بود. نمونه های آموزشی الگوریتم های مختلف مشابه بودند. برای نشان دادن اثربخشی مدلسازی الگوریتم های مختلف، ANN ها با بهترین پارامترها شبیه سازی شدند. منحنی های مدلسازی با بهترین پارامترهای الگوریتم های مختلف در شکل نمایش داده شده و خطاهای مطلق نیز در منحنی های مربوطه برای الگوریتم نشان داده شده است. شکل 6 نشان می دهد که خطای آزمایش ANN با LBSA بهتر از چهار الگوریتم دیگر است.

B. سیستم غیر خطی MISO

سیستم غیر خطی MISO استفاده شده در این آزمایش به شرح زیر می باشد:

$$y(t+1) = \frac{y(t)y(t-1)[y(t)+2.5]}{1+y^2(t)+y^2(t-1)} + u(t)$$

$$u(t) = \sin\left(\frac{2\pi t}{25}\right) \quad (19)$$

اندازه شبکه عصبی $1 \times 5 \times 3$ بود و تعداد متغیرهای الگوریتم های بهینه سازی 26 بود. علاوه بر این، 200 جفت داده از رابطه 19 به عنوان نمونه های آموزشی انتخاب شده بودند. پارامترهای آموزش 5 الگوریتم مشابه سیستم SISO می باشند. MSE قابل قبول 0.002 می باشد. جدول 8 نتایج 5 الگوریتم مختلف را نشان می دهد. نتایج نشان می دهند که MSEها در شرایط بهترین، میانگین و Std. با LBSA کوچکترین در میان 5 الگوریتم بودند. زمان آموزش jDE کوتاه ترین بود TStd. در BSA کوچکترین بود. TLBO و LBSA میزان موفقیت بالاتری نسبت به دیگر الگوریتم ها داشتند. شکل 7 فرآیند همگرایی 5 الگوریتم را نشان می دهد. این شکل نشان می دهد که سرعت همگرایی LBSA نسبت به دیگر الگوریتم ها بیشتر است. منحنی های مدلسازی با بهترین راه حل ها الگوریتم های مختلفی را در شکل 8 نشان می دهند، که نشان می دهد خطاهای مطلق LBSA و TLBO از دیگر

الگوریتم ها نسبتا کوچکتر است.

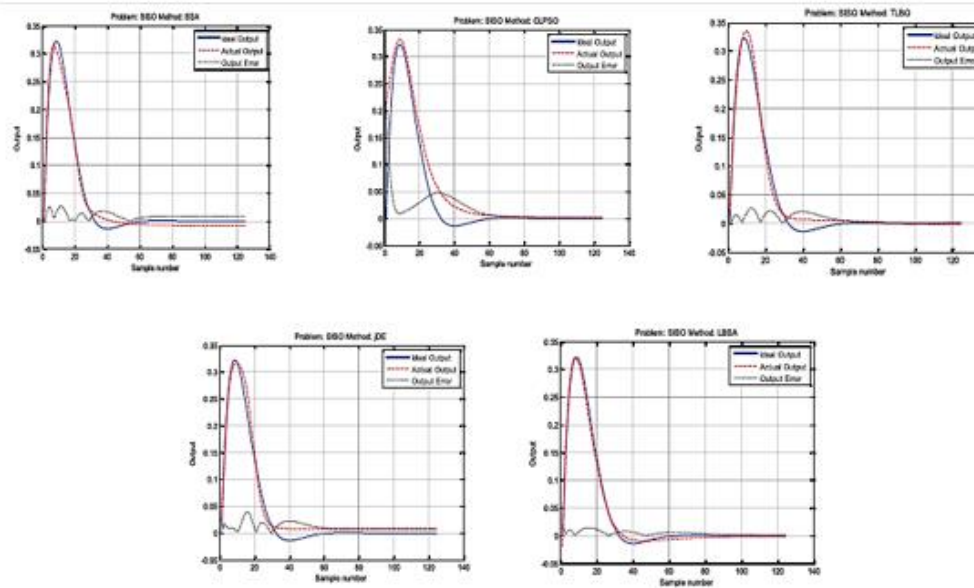


Fig. 6. The model and absolute error with optimized parameters of different algorithms for SISO system.

Table 8
Comparisons of five algorithms for MISO system over 30 runs.

Algorithms	BSA	CLPSO	TLBO	jDE	LBSA
best	8.8840E-03	1.6381E-02	7.3263E-04	2.1372E-03	6.7464E-04
mean	1.5097E-02	3.5236E-02	6.1081E-03	8.7818E-03	3.3982E-03
Std.	3.3759E-03	1.9407E-02	4.4069E-03	5.2586E-03	1.8934E-03
MT(sec)	26.8041	29.1934	29.6413	20.3282	26.8631
TStd.	1.1074E-01	1.7947E-01	1.1810E+00	1.4113E-01	1.2264E-01
SR	0	0	11	0	15

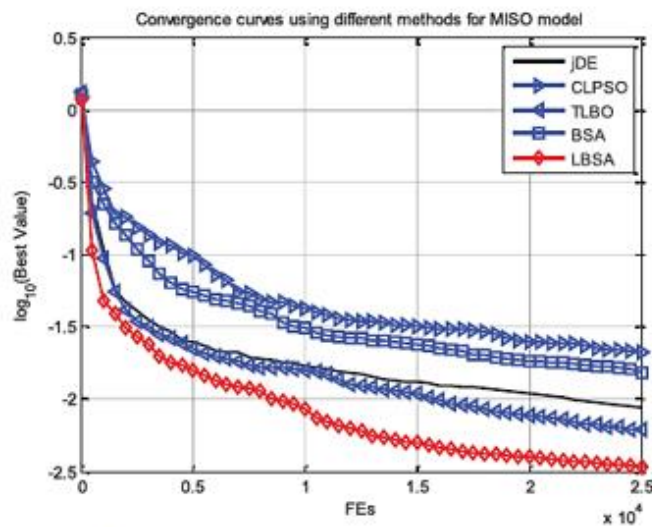


Fig. 7. The average fitness curves of five algorithms for MISO system.

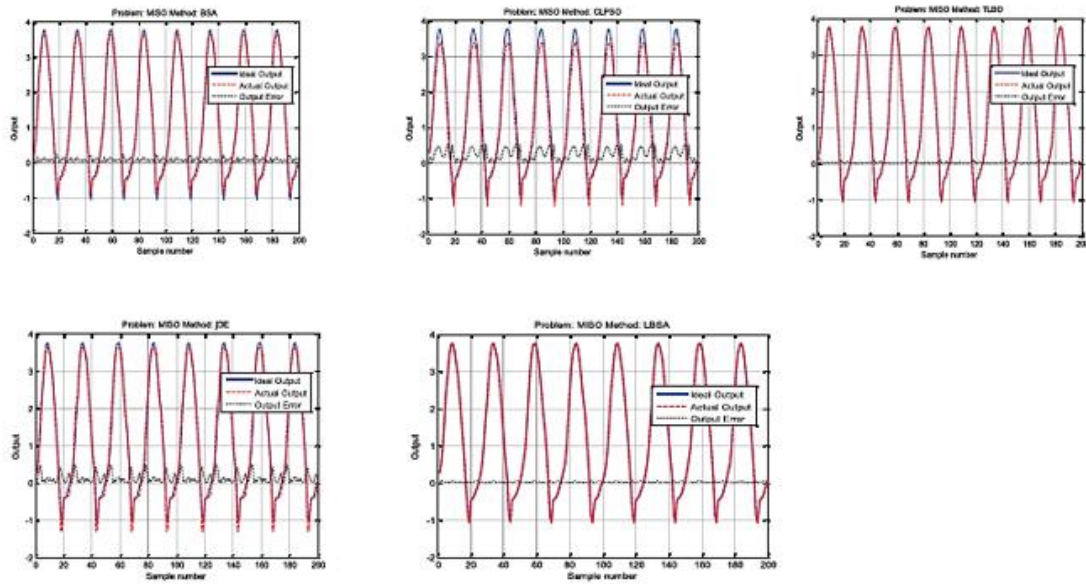


Fig. 8. The model and absolute error with optimized parameters of different algorithms for MISO system.

Table 9
Comparisons of five algorithms for MG model over 30 runs.

Algorithms		BSA	CLPSO	TLBO	jDE	LBSA
Training error	best	8.2669E-04	2.1381E-03	3.2300E-04	4.5339E-04	4.1732E-04
	mean	1.6452E-03	3.7599E-03	5.0356E-04	7.8107E-04	6.4917E-04
	Std.	4.9096E-04	1.1021E-03	1.9239E-04	2.1723E-04	2.4519E-04
Testing error	best	6.6138E-04	2.0534E-03	2.4551E-04	3.0173E-04	2.9654E-04
	mean	1.3129E-03	3.4043E-03	4.0320E-04	6.1615E-04	5.2960E-04
	Std.	4.2395E-04	9.1403E-04	1.5625E-04	2.1616E-04	2.3275E-04
Training time	MT(sec)	99.5724	106.4755	103.3196	81.5764	99.6394
	TStd.	3.3169E-01	7.3082E-01	4.6065E+00	5.9686E-01	3.6864E-01
SR		21	0	30	23	30

6.2 پیش بینی سری های زمانی آشوبی

A. سری های زمانی آشوبی مکی-گلاس (MG)

سیستم آشوبی مکی-گلاس [33,34] به شرح زیر است:

$$\dot{x}(t) = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx(t) \quad (20)$$

که $\tau = 17$ ، $a = 0.2$ و $b = 0.1$ است. در حالت کلی، از چهار نقطه ی قبلی $x(t-18)$ ، $x(t-12)$ و $x(t-6)$ برای پیش بینی نقطه بعدی $x(t+1)$ استفاده می شوند. هدف از این آزمایش ایجاد مدل پیش بینی یک گام به جلوی MG است، همانطور که در رابطه 21 نشان داده شده است:

$$\hat{x}(t+1) = f(x(t-18), x(t-12), x(t-6), x(t)) \quad (21)$$

برای پیش بینی مدل MG ، ANN باید شامل 4 واحد ورودی و یک واحد خروجی و واحدهایی از لایه پنهان باشد که در این آزمایش 5 بود. مقدار جمعیت همه ی الگوریتم ها 50 بود، و حداکثر F_E برابر 25000 بود. پارامترهای باقی مانده مشابه پارامترهای بکار رفته در بخش 6.1 بودند. 1000 جفت داده از مدل معادله 20 به عنوان آموزش و نمونه های آزمایش انتخاب شده بودند. در حالت قبل از 500 جفت داده به عنوان نمونه های آموزش استفاده شده بود و بقیه به عنوان نمونه های آزمایش انتخاب شده بودند. در حالت قبل 17 حالت بطور تصادفی تولید شدند. MSE به عنوان تابع برازش همه ی الگوریتم ها انتخاب شده بود و مقدار قابل قبول راه حل 0.002 است. اهمیت میانگین ، $Std.$ ، نرخ موفقیت و زمان اجرای آموزش و فرآیند آزمایش در جدول 9 نشان داده شده اند. این نتایج از 30 بار اجرا شدن مستقل هر 5 الگوریتم بدست آمدند. جدول نشان می دهد که $TLBO$ عملکرد بهتی نسبت به دیگر الگوریتم ها دارد. میانگین خطای آموزش و خطای آزمایش که با $LBSA$ بدست آمده رتبه دوم از 5 الگوریتم را دارد. نرخ موفقیت $TLBO$ و $LBSA$ 100 درصد بود. زمان آموزش jDE کوچکترین بود و $TStd.$ در BSA کوچکترین از 5 الگوریتم بود. این جدول همچنین نشان می دهد که عملکرد $LBSA$ نسبت به $TLBO$ برای مدل MG بدتر بود. فرآیند همگرایی متوسط MSE برای همه ی الگوریتم ها در شکل 9 نشان داده شده است. این شکل نشان می دهد که سرعت همگرایی $TLBO$ نسبت به دیگر الگوریتم ها برای مدل MG سریع تر است. $LBSA$ رتبه دوم سریع ترین عملکرد را در آزمایش دارد. منحنی های آزمایش و آموزش برای 1000 نمونه در شکل 10 نشان داده شداند. نتایج نشان می دهد که دقت تقریبی $TLBO$ و $LBSA$ بالاتر می باشد.




Fig. 9. The convergence curves of five algorithms for MG model.

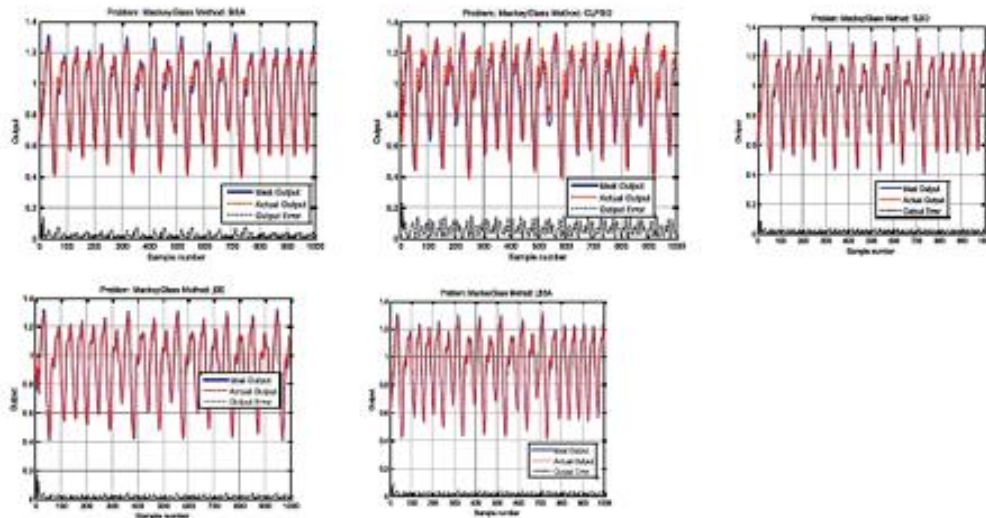


Fig. 10. The training and testing results with optimized ANN for MG model with different algorithms.

B. سری های زمانی آشوبی باکس-جنکینز

دومین سیستم آشوبی مدل کوره گاز باکس-جنکینز است. مجموعه داده های کوره گاز باکس - جنکینز از فرآیند احتراق مخلوط متان- هوا ثبت شده بود. در اینجا، 296 جفت داده $(x(t), u(t))$ از $t = 1$ تا $t = 296$ به عنوان نمونه های آموزش و آزمایش انتخاب شده بودند و همه ی مجموعه داده ها نرمالیزه شده بودند. علاوه بر این، $x(t)$ خروجی غلظت CO_2 بود و $u(t)$ ورودی دبی جریان گاز بود. علاوه بر این، $u(t - 4)$ و $x(t - 1)$ برای پیش

بینی حالت بعدی $x(t)$ مورد استفاده قرار گرفتند که به شرح زیر می باشد:

$$\hat{x}(t) = f(u(t-4), x(t-1)) \quad (22)$$

ساختار ANN دارای دو واحد ورودی، پنج واحد پنهان و یک واحد خروجی بود. 142 نقطه به عنوان نمونه های آموزش انتخاب شده بودند و 150 نقطه دیگر به عنوان نمونه های آزمایش مورد استفاده قرار گرفتند. پارامترهای آموزش همه ی الگوریتم ها مشابه آزمایش مدل MG می باشد. نتایج همه ی الگوریتم ها در جدول 10 نشان داده شده است. شکل 11 نشان دهنده تغییرات در متوسط MSE برای 30 بار اجرا شدن مستقل 5 الگوریتم می باشد. نتایج آزمایش و آموزش با پارامترهای بهینه ANN برای الگوریتم های مختلف در شکل 12 نشان داده شده است. جدول 10 نشان می دهد که LBSA عملکرد بهتری نسبت به دیگر الگوریتم ها با توجه به خطاهای آموزش و آزمایش دارد. میانگین زمان آموزش jDE کوچکترین از بین تمام الگوریتم ها بود و TStd در TLBO کوچکترین بود. چهار الگوریتم به یک راه حل قابل قبول همگرا شده اند. شکل 11 و 12 نشان می دهند که سرعت همگرایی LBSA نسبت به دیگر الگوریتم ها برای نمونه های آموزش و آزمایش عملکرد بهتری دارد.

Table 10
Comparisons of five algorithms for BJ model over 30 runs.

Algorithms		BSA	CLPSO	TLBO	jDE	LBSA
Training error	best	2.6298E-04	6.3800E-04	2.2648E-04	2.3587E-04	2.2342E-04
	mean	3.6289E-04	1.7420E-03	2.7155E-04	2.5739E-04	2.4860E-04
	Std.	8.5631E-05	1.0690E-03	7.1154E-05	2.0510E-05	1.9922E-05
Testing error	best	8.2501E-04	2.2737E-03	9.9168E-04	9.2444E-04	1.0593E-04
	mean	1.2824E-03	3.7696E-03	1.3044E-03	1.1370E-03	1.1334E-03
	Std.	2.7461E-04	1.1847E-03	2.5881E-04	1.6602E-04	1.6730E-04
Training time	MT(sec)	36.2576	3.6172E+01	36.8254	28.1255	36.3184
	TStd.	1.9027E-01	9.5481E-01	1.3737E-01	4.4479E-01	2.5097E-01
SR		30	21	30	30	30

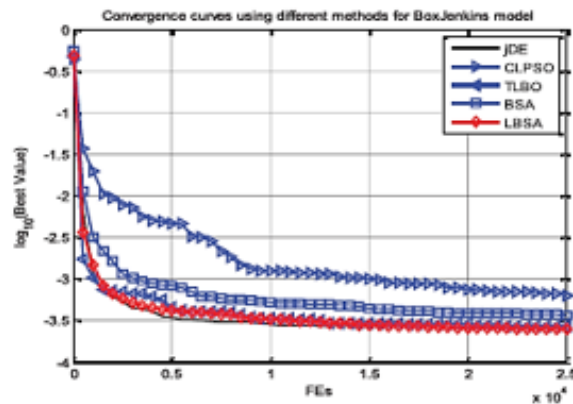


Fig. 11. The training and testing results for MG model with different algorithms.




Fig. 12. The training and testing results with optimized ANN for B_j model with different algorithms.

7. نتیجه گیری

در این مقاله، BSA بنیادی به توسعه LBSA توسط یک روش هدایت کننده یادگیری که فرآیند جهش BSA را تغییر می دهد پرداخته است. یادگیری از بهترین فرد در معادله جهش برای بهبود سرعت همگرایی الگوریتم استفاده شده است، و تنوع الگوریتم توسط جلوگیری از بدترین فرد نسل حاضر بهبود یافته است. سه روش یادگیری در یک معادله یکپارچه شده اند. از مقایسه TLBO پی بردیم که تنها یک F_E برای یک فرد در هر تکرار وجود دارد. چارچوب بنیادی BSA تغییر داده نشده است، و ویژگی ساده آن حفظ شده است. عملکرد LBSA در دو مجموعه آزمایش کلاسیک (CEC2005 و CEC214) آزمایش شده بود و مقایسه آن با نه الگوریتم دیگر نشان می دهد که LBSA عملکرد قابل مقایسه ای در بسیاری از موارد به دست می آورد. نتایج آزمایش برای مدلسازی سیستم غیرخطی و پیش بینی سری های زمانی آشوبی توسط ANN نیز نشان می دهد که LBSA عملکرد بیشتر مدل ها را به چالش می کشد. کارهای آتی باید روی استفاد کامل ساختار BSA توسط طراحی یک روش نگهداری تنوع قوی تر متمرکز شود زیرا LBSA نمی تواند بهینه سازی سراسری را برای برخی از توابع در CEC2005 و CEC2014 بدست آورد. علاوه بر این، گسترش دامنه کاربرد LBSA جهت تحقیق مهم می باشد.

سیاس گذاری

بخشی از این مقاله توسط بنیاد ملی علوم طبیعی چین (شماره اعتبار 61572224 ، 61304082 و 41475017) و صندوق ملی علوم برای دانش پژوهان جوان برجسته (شماره اعتبار 61425009) حمایت شده است. بخشی از این مقاله توسط پروژه تحقیقات علوم طبیعی در استان آنهویی (شماره گرانت KJ2015ZD36)، بنیاد علوم طبیعی در دانشکده ها و دانشگاه استان آنهویی (شماره گرانت KJ2016A639) و پروژه همکاری های بین المللی علوم و فناوری استان آنهویی (شماره گرانت 10080703003) حمایت شده است.

نویسندگان از استاد سوگان سان برای ارائه کد PSO و ویرایش متن و نظراتش تشکر می کنند.

References

- [1] J. Brest, S. Greiner, B. Boskovic, et al., Self-adapting control parameters in differential evolution: a comparative study on numerical benchmark problems, *IEEE Trans. Evol. Comput.* 10 (6) (2006) 646–657.
- [2] Q. Cai, M.G. Gong, L.J. Ma, Greedy discrete particle swarm optimization for large-scale social network clustering, *Inf. Sci.* 316 (2015) 503–516.
- [3] D.B. Chen, F. Zou, Z. Li, J.T. Wang, S.W. Li, An improved teaching-learning-based optimization algorithm for solving global optimization problem, *Inf. Sci.* 297 (2015) 171–190.
- [4] D.B. Chen, C.X. Zhao, Particle swarm optimization with adaptive population size and its application, *Appl. Soft. Comput.* 9 (2009) 39–48.
- [5] P. Civicioglu, Backtracking search optimization algorithm for numerical optimization problems, *Appl. Math. Comput.* 219 (15) (2013) 8121–8144.
- [6] M. Ghasemi, M.M. Ghanbarian, S. Ghavidel, S. Rahmani, E.M. Moghaddam, Modified teaching learning algorithm and double differential evolution algorithm for optimal reactive power dispatch problem: a comparative study, *Inf. Sci.* 278 (2014) 231–249.
- [7] M. Ghasemi, S. Ghavidel, M. Gitizadeh, E. Akbari, An improved teaching-learning-based optimization algorithm using Lévy mutation strategy for non-smooth optimal power flow, *Electr. Pow. Ener. Syst.* 65 (2015) 375–384.
- [8] M.G. Gong, Y. Wu, Q. Cai, Discrete particle swarm optimization for high-order graph matching, *Inf. Sci.* 328 (2016) 158–171.
- [9] K. Guney, A. Durmus, S. Basbug, Backtracking search optimization algorithm for synthesis of concentric circular antenna arrays, *Int. J. Antenn. Propag.* 2014 (2014) Article ID: 250841, 11 pages, <http://dx.doi.org/10.1155/2014/250841>.
- [10] B. Jürgen, H. Jan, Discrete particle swarm optimisation for ontology alignment, *Inf. Sci.* 192 (2012) 152–173.
- [11] H.S. Keesari, R.V. Rao, Optimization of job shop scheduling problems using teaching–learning-based optimization algorithm, *Opsearch* 51 (4) (2013) 545–561.
- [12] J. Kennedy, R.C. Eberhart, Particle swarm optimization, *Proc. IEEE Int. Conf. Neural Netw.* 4 (1995) 1942–1948.
- [13] X.L. Li, X.D. He, A hybrid particle swarm optimization method for structure learning of probabilistic relational models, *Inf. Sci.* 283 (2014) 258–266.
- [14] J.Q. Li, Q.K. Pan, K. Mao, A discrete teaching–learning-based optimization algorithm for realistic flow shop rescheduling problems, *Eng. Appl. Artif. Intell.* 37 (2015) 279–292.
- [15] J.J. Liang, A.K. Qin, P.N. Suganthan, S. Baskar, Comprehensive learning particle swarm optimizer for global optimization of multimodal functions, *IEEE Trans. Evol. Comput.* 10 (3) (2006) 281–295.
- [16] J.J. Liang, B.Y. Qu, P.N. Suganthan, Problem Definitions and Evaluation Criteria for the CEC 2014, 2013, pp. 1–32. Technical Report.
- [17] J. Lin, Oppositional backtracking search optimization algorithm for parameter identification of hyper chaotic systems, *Nonlinear Dyn.* (2014) 1–11.
- [18] L.B. Ma, Y.L. Zhu, Y. Liu, A novel bionic algorithm inspired by plant root foraging behaviors, *Appl. Soft. Comput.* 37 (2015) 95–113.
- [19] M.A. Medina, C.A.C. Coello, J.M. Ramirez, Reactive power handling by a multi-objective teaching learning optimizer based on decomposition, *IEEE Trans. Power Syst.* 28 (4) (2013) 3629–3637.
- [20] R. Mendes, J. Kennedy, J. Neves, The fully informed particle swarm: simpler, maybe better, *Appl. Soft. Comput.* 8 (3) (2004) 204–210.
- [21] H.B. Ouyang, L.Q. Gao, X.Y. Kong, et al., Hybrid harmony search particle swarm optimization with global dimension selection, *Inf. Sci.* (2016) 318–337 346–347.
- [22] V. Patel, V. Savsani, Optimization of a plate-fin heat exchanger design through an improved multi-objective teaching–learning based optimization (MO-ITLBO) algorithm, *Chem. Eng. Res. Des.* 92 (2014)

2371–2382.

- [23] T. Peram, K. Veeramachaneni, C.K. Mohan, Fitness-distance-ratio based particle swarm optimization, in: *In Proc. Swarm Intelligence Symp.*, 2003, pp. 174–181.
- [24] A.K. Qin, V.L. Huang, P.N. Suganthan, Differential evolution algorithm with strategy adaptation for global numerical optimization, *IEEE Trans. Evol. Comput.* 13 (2) (2009) 398–417.
- [25] A. Ratnaweera, S. Halgamuge, H. Watson, Self-organizing hierarchical particle swarm optimizer with time varying accelerating coefficients, *IEEE Trans. Evol. Comput.* 8 (3) (2004) 240–255.
- [26] R.V. Rao, Review of applications of TLBO algorithm and a tutorial for beginners to solve the unconstrained and constrained optimization problems, *Decis. Sci. Letters* 5 (2016), doi:10.5267/j.dsl.2015.9.003.
- [27] R.V. Rao, V.D. Kalyankar, Multi-pass turning process parameter optimization using teaching–learning-based optimization algorithm, *Scientia Iranica* 20 (3) (2013) 967–974.
- [28] R.V. Rao, V.D. Kalyankar, G. Waghmare, Parameters optimization of selected casting processes using teaching–learning-based optimization algorithm, *Appl. Math. Model.* 38 (2014) 5592–5608.
- [29] R.V. Rao, V. Patel, An elitist teaching–learning-based optimization algorithm for solving complex constrained optimization problems, *Int. J. Ind. Eng. Comput.* 3 (4) (2012) 535–560.
- [30] R.V. Rao, V. Patel, An improved teaching–learning-based optimization algorithm for solving unconstrained optimization problems, *Sci. Iran. Trans. D* 20 (3) (2013) 710–720.
- [31] R.V. Rao, V.J. Savsani, D.P. Vakharia, Teaching–learning-based optimization: an optimization method for continuous non-linear large scale problems, *Inf. Sci.* 183 (1) (2012) 1–15.
- [32] P.K. Roy, A. Sur, D.K. Pradhan, Optimal short-term hydro-thermal scheduling using quasi-oppositional teaching learning based optimization, *Eng. Appl. Artif. Intell.* 26 (2013) 2516–2524.
- [33] B. Samanta, Prediction of chaotic time series using computational intelligence, *Expert Syst. Appl.* 38 (9) (2011) 11406–11411.
- [34] X. Song, X. Zhang, S. Zhao, L. Li, Backtracking search algorithm for effective and efficient surface wave analysis, *J. Appl. Geophys.* 114 (2015) 19–31.
- [35] P.N. Suganthan, N. Hansen, J.J. Liang, Problem definitions and evaluation criteria for the CEC 2005 special session on real-parameter optimization, 2005, pp. 1–50. Technical Report.
- [36] C.Y. Tsai, C.J. Chen, A PSO-AB classifier for solving sequence classification problems, *Appl. Soft. Comput.* 27 (2015) 11–27.
- [37] H.F. Wang, I. Moon, S.X. Yang, et al., A memetic particle swarm optimization algorithm for multimodal optimization problems, *Inf. Sci.* 197 (2012) 38–52.
- [38] H. Wang, H. Sun, C.H. Li, Diversity enhanced particle swarm optimization with neighborhood search, *Inf. Sci.* 223 (2013) 119–135.
- [39] L. Wang, F. Zou, X.H. Hei, An improved teaching–learning-based optimization with neighborhood search for applications of ANN, *Neurocomputing* 143 (2014) 231–247.
- [40] L. Wang, Y. Zhong, Y.Y. Zhao, W. Wang, et al., A hybrid backtracking search optimization algorithm with differential evolution, *Math. Probl. Eng.* 501 (2015) 769245.
- [41] Z.L. Yang, K. Li, A. Foley, C. Zhang, A new self-learning TLBO algorithm for RBF neural modelling of batteries in electric vehicles, 2014 IEEE Cong. on Evol. Comput. (CEC), 2014 July 6–11.
- [42] Z.H. Zhan, J. Zhang, Y. Li, et al., Adaptive particle swarm optimization, *IEEE Trans. Syst. Man Cy. B* 39 (6) (2009) 1362–1381.
- [43] C.J. Zhang, Q. Lin, L. Gao, Backtracking Search Algorithm with three constraint handling methods for constrained optimization problems, *Expert Syst. Appl.* 42 (2015) 7831–7845.
- [44] L. Zhao, Y. Yang, PSO-based single multiplicative neuron model for time series prediction, *Expert Syst. Appl.* 36 (2) (2009) 2805–2812.
- [45] F. Zou, L. Wang, X.H. Hei, et al., Teaching-learning-based optimization with dynamic group strategy for global optimization, *Inf. Sci.* 273 (2014) 112–131.