

PSO-LA: یک مدل جدید برای بهینه سازی

محمد رضا میبدی*

محمد شبانی*

چکیده

حرکت جمعی ذرات یک تکنیک بهینه سازی است که بر اساس قوانین احتمال کار میکند و از حرکت گروهی پرندگان و ماهیها هنگامی که دنبال غذا میگردند، الهام گرفته شده است. در این روش هر یک از ذرات سعی میکند به سمتی حرکت کنند که بهترین تجربه های شخصی و گروهی در آن نقاط روی داده است. مشکل اصلی این مدل که در بسیاری از مسایل، به خصوص مسایل چند قله ای بروز میکند، مساله گیر افتادن در بهینه های محلی است. در این مقاله یک مدل جدید بر اساس PSO به نام PSO-LA پیشنهاد میشود که در آن از یک اتوماتای یادگیر برای تنظیم رفتار ذرات و برقراری موازنۀ بین جستجوی سراسری و جستجوی محلی استفاده میشود. نتایج آزمایشات بر روی مسایل نمونه نشان داده اند که روش ارائه شده از عملکرد بهتری در مقایسه با مدل PSO استاندارد برخوردار است.

کلمات کلیدی

حرکت دسته جمعی ذرات، اتوماتاهای یادگیر، بهینه سازی

PSO-LA: A New Model for Optimization

Mohammad Sheybani

Mohammad Reza Meybodi

Abstract

Particle swarm optimization (PSO) is a population based statistical optimization technique which inspired by social behavior of bird flocking or fish schooling. PSO starts with a random population of particles. Each particle of the population tries to move toward the points of search space in which the best experience of the particle itself and also the best experience of the population occurred. The main weakness of PSO especially in multi modal problems is trapping in local optimums. In this paper a new PSO model called PSO-LA is proposed in which a learning automaton takes the role of configuring the behavior of particles and also creating a balance between the process of global and local search. The results of experiments conducted on some standard problems show that the proposed algorithm produces better results than the standard PSO.

Keywords

Particle Swarm, Learning Automata, Optimization

* دانشجویی کارشناسی ارشد دانشکده مهندسی کامپیوتر و فناوری اطلاعات دانشگاه صنعتی امیرکبیر، sheybani@ce.aut.ac.ir

† عضو هیئت علمی دانشکده مهندسی کامپیوتر و فناوری اطلاعات دانشگاه صنعتی امیرکبیر، meybodi@ce.aut.ac.ir

۱- مقدمه

گام بعد مورد استفاده قرار می‌گیرد. هدف از معرفی این پارامتر این بوده است که برقراری تعادل بین جستجوی محلی و جستجوی سراسری، بسته به نوع مساله بتواند قابل تنظیم باشد. در برخی از کاربردها از یک مقدار وزن میانی ثابت استفاده شده است ولی معمولاً وزن میانی در ابتدا مقدار بالاتری دارد و با گذشت زمان مقدار آن به صورت خطی کاهش می‌یابد و به این ترتیب ذرات در ابتدا بیشتر سعی در شناسایی محلهای جدید از فضای جستجو دارند و با گذشت زمان بیشتر میل به دنباله روی پیدا میکنند. کاهش مقدار وزن میانی به صورت خطی روشی بسیار ساده است که توانایی بکارگیری کامل دانش اولیه راجع به مساله و نیز استفاده از بازخورد سیستم را ندارد.

برخی از محققان سعی کرده اند تا با افزودن نویز به حرکات ذرات در الگوریتم استاندارد PSO باعث حرکات متنوعتری شوند و بدین صورت مشکل بهینه های محلی را حل کنند^{[۹][۱۰]}. برخی دیگر از راه حلها برای حل مشکل بهینه های محلی از طریق ترکیب الگوریتم PSO با الگوریتمهای دیگر مانند الگوریتمهای ژنتیک^۳ و روش بالا رفتن در امتداد شبیه^۴ و الگوریتم سرد کردن تدریجی^۵ حاصل شده است^{[۱۱][۱۲]}.

یک اتوماتای یادگیر^[۳]، مانشینی است که میتواند تعدادی متناهی عمل را انجام دهد. هر عمل انتخاب شده توسط یک محیط احتمالی ارزیابی میشود و نتیجه ارزیابی در قالب سیگنالی مشبت یا منفی به اتوماتای یادگیر داده میشود و اتوماتا از این پاسخ در انتخاب عمل بعدی استفاده میکند و بدین ترتیب به سمت انتخاب عملی که بیشترین پاداش را از محیط میگیرد، میل میکند. به عبارت بهتر، اتوماتا عملی را که بیشترین پاداش را از محیط دریافت میکند یاد می‌گیرد.

اتوماتای یادگیر برای بهبود قدرت یادگیری بسیاری از الگوریتمها مورد استفاده قرار گرفته است که از آن جمله میتوان به شبکه های عصبی^{[۱۴][۱۵]} و الگوریتمهای ژنتیک^{[۱۶][۱۷]} و همچنین حرکت PSO دسته جمعی ذرات باینری^[۱۲] اشاره نمود. در [۱۲] مدل PSO باینری بر پایه اتوماتای یادگیر ارائه شده است. در این روش از یک اتوماتون یادگیر در هر بعد ذره استفاده شده است. هر کدام از این اتوماتاهای یادگیر دارای دو عمل ۰ و ۱ میباشد و به عنوان مغز متفکر ذره عمل میکند و حرکت آن را در فضای حالت محدود به ۰ و ۱ کنترل و راهبری مینماید. این مدل نتایج بهتری در مقایسه با مدل باینری استاندارد^[۲] در حل مسایل نمونه داشته است.

در این مقاله مدل جدیدی به نام PSO-LA پیشنهاد میشود. در مدل پیشنهادی، از یک اتوماتای یادگیر برای تنظیم رفتار ذرات استفاده شده است. اتوماتای یادگیر در هر گام تعیین میکند که ذرات به مسیر فعلی ادامه دهند و یا به دنباله روی از بهترین ذرات پیدا شده

حرکت دسته جمعی ذرات^۱ یک تکنیک کارا برای حل مسایل بهینه سازی است که بر مبنای قوانین احتمال و بر اساس جمعیت کار میکند. در این روش هر یک از اعضای جمعیت که ذره نام دارند، سعی میکنند با تنظیم مسیر خود و حرکت به سمت بهترین تجربه شخصی و بهترین تجربه جمعی گروه، به سوی راه حل نهایی حرکت کنند. از آنجا که در این الگوریتم ذرات به تدریج به سمت بهترین راه حل پیدا شده تا به حال میل میکنند، اگر این راه حل یک بهینه محلی باشد ذرات همگی به سمت آن میروند و الگوریتم استاندارد PSO راهکاری برای خروج از این بهینه محلی ارائه نمیدهد. این بزرگترین مشکل PSO استاندارد است که سبب میشود در حل مسایل چند قله ای مخصوصاً با فضای حالت بزرگ ناتوان باشد.

یکی از اعمال صورت گرفته برای مقابله با مشکل بهینه های محلی در الگوریتم حرکت دسته جمعی ذرات، استفاده از جهش^۲ است [۶][۷][۸]. در [۶] و [۷] از جهش گاویسی در PSO استاندارد و نیز نسخه هایی تغییر یافته از آن استفاده شده است. در این مقالات مدل PSO با جهش ارائه شده توسط توابعی با حد اکثر دو بعد آزمایش شده اند و جوابهای مناسبی داشته اند. در [۸] برای جهش از توزیع کوشی استفاده شده است. به این ترتیب که هر ذره با احتمال P_{mutate} جهش پیدا کنند. هرگاه ذره ای برای جهش انتخاب شد، هر یک از اجزای بردار آن ذره به احتمال $1/d$ که d تعداد ابعاد مساله است، ممکن است چار جهش شوند. برای جهش دادن هر جزء از یک ذره یک عدد به صورت تصادفی از توزیع کوشی انتخاب میشود و با مقدار جزء مربوطه از بردار ذره جمع میشود. روش ارائه شده برای برخی مسایل با فضای حالت‌های بزرگ، جوابهای مناسبی داشته است.

در الگوریتم حرکت دسته جمعی ذرات استاندارد، برای محاسبه سرعت ذره در گام بعد، کل سرعت فعلی ذره محاسبه میشود. در واقع سرعت ذره در هر گام از دو قسمت تشکیل میشود که قسمت اول سرعت فعلی ذره و قسمت دوم مربوط به دنبال کردن بهترین تجربه شخصی و بهترین تجربه گروه است. بدون قسمت دوم، الگوریتم حالت یک جستجوی سراسری کوکورانه را خواهد داشت و بدون قسمت اول، الگوریتم به جستجوی محلی در نزدیکی بهترین ذره تبدیل خواهد شد که در رسیدن به قسمتهای زیادی از فضای جستجو ناتوان خواهد بود. الگوریتم حرکت دسته جمعی ذرات با ترکیب این دو قسمت، سعی میکند که به نوعی تعادل را بین جستجوی سراسری و محلی ایجاد نماید.

در [۵] پارامتری با نام وزن میانی تعریف شده است. وزن میانی در واقع ضریبی از سرعت فعلی ذره است که در تعیین سرعت ذره در

که همسایگان توپولوژیکی اش هستند، انتخاب و تنها آنها را در اعمال خود دخیل می‌کند که در این حالت بهترین راه حل محلی که با b_{best} نشان داده می‌شود، به جای g_{best} مورد استفاده قرار می‌گیرد. پس از یافتن بهترین مقادیر، سرعت و مکان هر ذره با استفاده از معادلات (۱) و (۲) به روز می‌شوند.

$$v[] = v[] + c1 * \text{rand}() * (pbest[] - \text{position}[]) \quad (1)$$

$$c2 * \text{rand}() * (gbest[] - \text{position}[])$$

$$\text{position}[] = \text{position}[] + v[] \quad (2)$$

در معادلات (۱) و (۲)، $v[]$ سرعت ذره و $\text{position}[]$ محل فعلی ذره هستند که هر دو آرایه هایی به طول تعداد ابعاد مساله می‌باشند. $Rand()$ یک عدد تصادفی در بازه $(0,1)$ است. $C1$ و $C2$ نیز پارامترهای یادگیری هستند و معمولاً $C1=C2=2$ در نظر گرفته می‌شود. سرعت ذرات در هر بعد به یک مقدار V_{max} محدود می‌شوند. اگر مجموع شتابها باعث شوند که سرعت در یک بعد از V_{max} بیشتر شود، مقدار سرعت در آن بعد برابر با V_{max} قرار می‌گیرد. شبیه کد الگوریتم PSO در شکل (۱) مشاهده می‌شود.

سمت راست معادله (۱) از سه قسمت تشکیل شده است که قسمت اول، سرعت فعلی ذره است و قسمتهای دوم و سوم تغییر سرعت ذره و چرخش آن به سمت بهترین تجربه شخصی و بهترین تجربه گروه را به عهده دارند. اگر قسمت اول را در این معادله در نظر نگیریم، آنگاه سرعت ذرات تنها با توجه به موقعیت فعلی و بهترین تجربه ذره و بهترین تجربه جمع تعیین می‌شود. به این ترتیب، بهترین ذره جمع، در مکان خود ثابت باقی می‌ماند و سایرین به سمت آن ذره حرکت می‌کنند. در واقع حرکت دسته جمعی ذرات بدون قسمت اول معادله (۱)، پروسه ای خواهد بود که طی آن فضای جستجو به تدریج کوچک می‌شود و جستجوی محلی حول بهترین ذره شکل می‌گیرد. در مقابل اگر فقط قسمت اول معادله (۱) را در نظر بگیریم، ذرات راه عادی خود را می‌روند تا به دیواره محدوده برسند و به نوعی جستجوی سراسری را انجام میدهند [۵].

در معادله (۱) با ترکیب این دو عامل سعی شده است تا موازنۀ ای بین جستجوی محلی و سراسری برقرار گردد. در [۵]، یک پارامتر جدید توسط ارائه دهنده‌گان الگوریتم اولیه PSO، ارائه گردید. این پارامتر جدید وزن میانی نامیده و با w نشان داده می‌شود. هدف از معرفی این پارامتر برقراری موازنۀ بهتر بین جستجوی محلی و جستجوی سراسری است. به این منظور در معادله (۱)، این ضریب در سرعت اولیه ذره ضرب می‌شود و به عبارتی تنها قسمتی از سرعت اولیه به سرعت آینده ذره منتقل می‌شود و به این ترتیب معادله (۱) به شکل معادله (۳) تغییر می‌کند.

تاکنون بپردازند. در الگوریتم پیشنهادی وظیفه برقراری تعادل بین جستجوی سراسری و جستجوی محلی که در [۵] بر عهده ضریب میانی گذاشته شده است، توسط اتوماتی یادگیر انجام می‌شود. استفاده از اتوماتی یادگیرداری دو مزیت عمده می‌باشد: اولاً می‌توان از دانش موجود در تعیین روند تغییرات وزن میانی استفاده نمود و ثانیاً این روند می‌تواند با گرفتن بازخورد از اجرای الگوریتم اصلاح گردد.

ادامه این گزارش به صورت زیر سازماندهی شده است. بخش ۲ به معرفی مدل PSO می‌پردازد. در بخش سوم اتوماتی یادگیر به اختصار معرفی شده است. در بخش ۴ مدل پیشنهادی شرح داده شده است. بخش پنجم نتایج شبیه سازیها را ارائه می‌کند و بخش پایانی به نتیجه گیری می‌پردازد.

۲- حرکت دسته جمعی ذرات

حرکت جمعی ذرات (PSO)، یک تکنیک بهینه سازی احتمالی است که بر مبنای جمعیت کار می‌کند. این روش در سال ۱۹۹۵ توسط دکتر ابرهارت و دکتر کندی ارائه شد [۱] و ایده اصلی آن از رفتار دسته جمعی ماهیها یا پرندگان به هنگام جستجوی غذا الهام گرفته شده است. گروهی از پرندگان در فضایی به صورت تصادفی دنبال غذا می‌گردند. تنها یک تکه غذا در فضایی مورد بحث وجود دارد. هیچ یک از پرندگان محل غذا را نمیدانند. یکی از بهترین استراتژیها میتواند دنبال کردن پرنده‌ای باشد که کمترین فاصله را تا غذا داشته باشد. این استراتژی در واقع جانمایه الگوریتم PSO است.

در الگوریتم PSO، هر راه حل که به آن یک ذره گفته می‌شود، معادل یک پرنده در الگوی حرکت جمعی پرندگان می‌باشد. هر ذره یک مقدار شایستگی دارد که توسط یکتابع شایستگی محاسبه می‌شود. هر چه ذره در فضای جستجو به هدف- غذا در مدل حرکت پرندگان- نزدکتر باشد، شایستگی بیشتری دارد. همچنین هر ذره دارای یک سرعت است که هدایت حرکت ذره را بر عهده دارد. هر ذره با دنبال کردن ذرات بهینه در حالت فعلی، به حرکت خود در فضای مساله ادامه میدهد.

آغاز کار PSO به این شکل است که گروهی از ذرات (راه حلها) به صورت تصادفی به وجود می‌آیند و با به روز شدن در طی نسلها سعی در یافتن راه حل بهینه مینمایند. در هر گام، هر ذره با استفاده از دو بهترین مقدار به روز می‌شود. اولین مورد، بهترین موقعیتی است که تا کنون ذره موفق به رسیدن به آن شده است. موقعیت مذکور با نام $pbest$ شناخته و نگهداری می‌شود. بهترین مقدار دیگری که توسط الگوریتم مورد استفاده قرار می‌گیرد، بهترین موقعیتی است که تا کنون توسط جمعیت ذرات بدست آمده است. این موقعیت با $gbest$ نمایش داده می‌شود. در برخی ویرایشهای PSO، ذره، قسمتهایی از جمعیت را

```

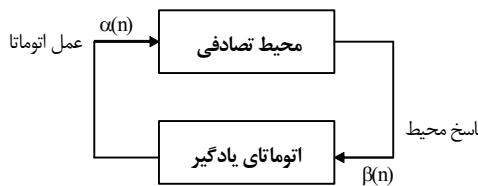
xid(t+1) = 1
else
xid(t+1) = 0

```

$$V[] = w * v[] + c1 * \text{rand}() * (pbest[] - position[]) + c2 * \text{rand}() * (gbest[] - position[]) \quad (3)$$

۳- اتوماتاهای یادگیر*

اتوماتی یادگیر [۳]، ماشینی است که میتواند تعدادی متنه ای عمل را انجام دهد. هر عمل انتخاب شده توسط یک محیط احتمالی ارزیابی میشود و نتیجه ارزیابی در قالب سیگنالی مثبت یا منفی به اتوماتا داده میشود و اتوماتا از این پاسخ در انتخاب عمل بعدی تاثیر میگیرد. هدف نهایی این است که اتوماتا یاد بگیرد تا از بین اعمال خود بهترین عمل را انتخاب کند. بهترین عمل، عملی است که احتمال دریافت پاداش از محیط را به حداقل برساند. اتوماتی یادگیر در تعامل با محیط، در شکل (۲) مشاهده میشود.



شکل (۲): ارتباط بین اتوماتی یادگیر و محیط

محیط را می‌توان توسط سه تابی $E \equiv \{\alpha, \beta, c\}$ نشان داد که در آن $\{\alpha_1, \alpha_2, \dots, \alpha_r\} \equiv \alpha$ مجموعه ورودیها، $\{\beta_1, \beta_2, \dots, \beta_m\} \equiv \beta$ مجموعه خروجیها و $\{c_1, c_2, \dots, c_r\} \equiv c$ مجموعه احتمالهای جریمه می‌باشد. هرگاه β مجموعه دو عضوی باشد، محیط از نوع P می‌باشد. در چنین محیطی $\beta_1 = 1$ به عنوان جریمه و $\beta_2 = 0$ به عنوان پاداش در نظر گرفته می‌شود. در محیط از نوع Q، $\beta(n)$ می‌تواند به طور گسته یک مقدار از مقادیر محدود در فاصله $[0, 1]$ باشد و در محیط از نوع S، $\beta(n)$ متغیری تصادفی در فاصله $[0, 1]$ است. c احتمال اینکه عمل α نتیجه نامطلوب داشته باشد می‌باشد. در محیط ایستا مقادیر c بدون تغییر می‌مانند. حال آنکه در محیط غیر ایستا این مقادیر در طی زمان تغییر می‌کنند. اتوماتی یادگیر با ساختار متغیر را میتوان توسط چهارتایی $\{\alpha, \beta, p, T\}$ نشان داد که $\alpha = \{\alpha_1, \dots, \alpha_r\}$ مجموعه عملهای اتوماتا، $\beta = \{\beta_1, \dots, \beta_m\}$ مجموعه ورودیهای اتوماتا، $p = \{p_1, \dots, p_r\}$ بردار احتمال انتخاب هریک از عملها و $T[\alpha(n), \beta(n), p(n)] = p(n+1)$ الگوریتم یادگیری می‌باشد. الگوریتم زیریک نمونه از الگوریتمهای یادگیری خطی است. فرض کنید عمل α در مرحله n انتخاب شود.

- پاسخ مطلوب

```

For each particle
    Initialize particle
End For
Do
    For each particle
        Calculate fitness value of the particle fp
        /*updating particle's best fitness value so far*/
        If fp is better than pBest
            set current value as the new pBest
    End For
    /*updating population's best fitness value so far*/
    Set gBest to the best fitness value of all particles
    For each particle
        Calculate particle velocity according equation (1)
        Update particle position according equation (2)
    End For
    While maximum iterations OR
        minimum error criteria is not attained

```

شکل ۱- شبیه کد الگوریتم PSO

وزن میانی میتواند یک ضریب ثابت، یکتابع خطی با زمان و یا حتی یکتابع غیرخطی با زمان باشد. در بسیاری از کاربردها وزن میانی به صورت یکتابع خطی نزولی با زمان در نظر گرفته میشود. به این ترتیب در ابتدا قسمت بیشتری از سرعت فعلی ذره در سرعت آینده اش دخیل میشود و با گذشت زمان، این میزان کاهش می‌یابد. به عبارت بهتر، در ابتدا ذرات میل بیشتری به حرکات انفجاری و تجربه‌های تازه دارند و با گذشت زمان این میل جای خود را به دنباله روی بیشتر از بهترینها میدهد. این روش در بسیاری موارد میتواند کاهش دهنده مشکل گیر افتادن در مینیمم‌های محلی باشد.

مدل بازنگری PSO برای حل مسایل گسسته، در سال ۱۹۹۷ توسط ارائه دهنده‌گان الگوریتم استاندارد، معرفی شد [۲]. در این مدل موقعیت هر ذره در هر بعد با یکی از دو مقدار ۰ یا ۱ مشخص می‌گردد. به این ترتیب، ذره در یک فضای محدود به ۰ و ۱ حرکت می‌کند و سرعت ذره در هر بعد برابر با احتمال یک بودن موقعیت ذره در آن بعد خواهد بود. بروز رسانی سرعت همچنان مطابق با معادله (۱) انجام میشود. سپس ابتدا سرعت بدست آمده در هر بعد با استفاده ازتابع سیگموید به بازه $[0, 1]$ منتقل می‌گردد و آنگاه موقعیت جدید ذره در هر بعد مطابق با معادله (۴) محاسبه می‌گردد. (rand) یک مقدار تصادفی در بازه $[0, 1]$ است.

If ($\text{rand}() < \text{sigmoid}(v_{id}(t+1))$) then (۴)

عملی که اتوماتی یادگیر در هر گام بر میگزیند، تعیین کننده شیوه بروز کردن سرعت ذرات در آن گام میباشد. در صورت انتخاب عمل «دنباله روی»، تنها دنبال کردن بهترین تجربه شخصی و بهترین تجربه گروهی، در به روز نمودن سرعت ذرات مد نظر قرار خواهد گرفت و از سرعت فعلی ذرات صرف نظر میشود که در این صورت بروزرسانی سرعت ذرات مطابق با فرمول (۷) انجام میگردد. در صورت انتخاب عمل «دامه مسیر فعلی» سرعت جدید ذرات برابر با سرعت فعلی آنها خواهد بود و ذره همچنان مسیری فعلی را ادامه خواهد داد.

$$V[i] = c1 * \text{rand}() * (\text{pbest}[i] - \text{position}[i]) + c2 * \text{rand}() * (\text{gbest}[i] - \text{position}[i]) \quad (7)$$

در واقع انتخاب عمل «دنباله روی»، انجام یک جستجوی محلی را در بی خواهد داشت و انتخاب عمل «دامه مسیر فعلی»، باعث جستجوی سراسری و کشف قسمتهایی ناشناخته از فضای جستجو میگردد. وظیفه اتوماتی یادگیر، یادگیری بردار احتمال مطلوب و برقراری تعادل بین جستجوی سراسری و جستجوی محلی در فرایند جستجو میباشد.

شیوه ارزیابی عمل انتخاب شده، به این صورت است که موقعیت فعلی هر ذره با موقعیت قبلی ان مقایسه میشود. چنانچه c_{imp} درصد از جمعیت موقعیتشان بهبود یافته باشد، عمل انتخاب شده ثابت و در غیر اینصورت منفی ارزیابی میشود. c_{imp} از پارامترهای الگوریتم پیشنهادی است که بایستی با توجه به نوع مساله و اتوماتی یادگیر بکار گرفته شده، تنظیم گردد. شکل (۴) شبکه کد الگوریتم پیشنهادی را نشان میدهد.

```

Initialize the LA
For each particle
    Initialize particle
End For
Do
    The LA selects an action ac
    For each particle
        Calculate fitness value of the particle fp
        /*updating particle's best fitness value so far*/
        If fp is better than pBest
            set current value as the new pBest
    End For
    /*updating population's best fitness value so far*/
    Set gBest to the best fitness value of all particles
    For each particle
        if ac is "follow the best"
            Calculate particle velocity according equation (7)
            Update particle position according equation (2)
    End For
While maximum iterations OR
    minimum error criteria is not attained

```

شکل (۴) - شبکه کد الگوریتم PSO-LA

$$\begin{aligned} p_i(n+1) &= p_i(n) + a[1 - p_i(n)] \\ p_j(n+1) &= (1-a)p_j(n) \quad \forall j \neq i \end{aligned} \quad (5)$$

- پاسخ نامطلوب

$$\begin{aligned} p_i(n+1) &= (1-b)p_i(n) \\ p_j(n+1) &= (b/r-1)+(1-b)p_j(n) \quad \forall j \neq i \end{aligned} \quad (6)$$

در روابط (۵) و (۶)، a پارامتر پاداش و b پارامتر جرمیمه می باشند. با توجه به مقادیر a و b سه حالت زیر را می توان در نظر گرفت. زمانیکه a و b با هم برابر باشند، الگوریتم را L_{RP} می نامیم، زمانیکه a از b خیلی کوچکتر باشد، الگوریتم را L_{RP} می نامیم و زمانیکه b مساوی صفر باشد الگوریتم را L_{RI} مینامیم [۴]. شکل (۳) شبکه کد اتوماتی یادگیر با ساختار متغیر را نشان میدهد.

```

Initialize p to [1/s,1/s,...,1/s] /*s is the number of actions*/
While not done
    Select an action i based on the probability vector p
    Evaluate action and return a reinforcement signal β
    Update probability vector using learning rule
End While

```

شکل (۳) : اتوماتی یادگیر با ساختار متغیر

۴- مدل پیشنهادی (PSO-LA)

در این بخش یک الگوریتم حرکت دسته جمعی ذرات بر پایه اتوماتی یادگیر که انرا PSO-LA مینامیم پیشنهاد میگردد. مانند الگوریتم حرکت دسته جمعی ذرات، در این الگوریتم نیز یک جمعیت از ذرات وجود دارد و هر یک از ذرات دارای یک موقعیت و سرعت اولیه هستند. تفاوت الگوریتم پیشنهادی با الگوریتم استاندارد این است که الگوریتم پیشنهادی از یک اتوماتی یادگیر برای کنترل رفتار ذرات استفاده میکند. این اتوماتی یادگیر دارای دو عمل «دنباله روی» و «دامه مسیر فعلی» میباشد. در ابتدا، موقعیت و سرعت ذرات و همچنین بردار احتمالات انتخاب اعمال اتوماتی یادگیر مقداردهی اولیه میشوند. سپس تا زمانیکه حداکثر تعداد گامها انجام گردد و یا هدف مورد نظر حاصل شود، مراحل زیر تکرار میشوند:

- اتوماتی یادگیر یکی از اعمال خود را بر اساس بردار احتمال اعمالش، انتخاب میکند.
- با توجه به عمل انتخاب شده، نحوه بروزرسانی سرعت ذرات تعیین میشود و سپس ذرات، سرعت و موقعیت خود را بروز میکنند.
- بر اساس نتایج به روزرسانی موقعیت ذرات، عمل اتوماتی یادگیر، ارزیابی میشود و بردار احتمال انتخاب اعمال اتوماتی یادگیر اصلاح میشود.

۵- نتایج شبیه سازیها

جدول ۲- نتایج مقایسه PSO و PSO-LA تابع روزنبراک

متوسط	بهترین	الگوریتم	ابعاد
۳۵۲,۸۶	۱۴,۳۹	PSO-Std	۱۰
۱۱,۳۳	۰,۴۳	PSO-I.W	
۱۰,۹۹	۰,۳۶	PSOLA-L _{RP}	
۷,۱۱	۰,۷۳	PSOLA-L _{RI}	
۳۱۶۷۴,۲۶	۵۸۶۴,۰۶	PSO-Std	۲۰
۲۵,۲۴	۱۴,۷۲	PSO-I.W	
۲۹,۳۵	۱۱,۴۸	PSOLA-L _{RP}	
۳۱,۹۸	۱۴,۶۲	PSOLA-L _{RI}	
۴۱۲۵۱۵,۰۴	۵۲۰,۵۷,۶۴	PSO-Std	۳۰
۸۹,۰۰	۲۹,۱۵	PSO-I.W	
۶۷,۰۵	۲۳,۶۹	PSOLA-L _{RP}	
۶۷,۸۴	۲۲,۹۸	PSOLA-L _{RI}	

جدول ۳- نتایج مقایسه PSO و PSO-LA برای تابع رستریجین

متوسط	بهترین	الگوریتم	ابعاد
۱۰,۱۴	۴,۹۷	PSO-Std	۱۰
۸,۶۹	۳,۶۵	PSO-I.W	
۹,۳۹	۳,۰۸	PSOLA-L _{RP}	
۹,۵۳	۴,۰۱	PSOLA-L _{RI}	
۲۸,۲۱	۱۰,۰۵	PSO-Std	۲۰
۲۸,۹۳	۱۰,۹۹	PSO-I.W	
۲۱,۸۴	۹,۲۳	PSOLA-L _{RP}	
۲۲,۷۲	۱۱,۶	PSOLA-L _{RI}	
۵۷,۱۰	۲۸,۴۹	PSO-Std	۳۰
۳۴,۱۶	۲۴,۲۵	PSO-I.W	
۳۱,۸۶	۱۶,۹۲	PSOLA-L _{RP}	
۳۲,۲۱	۱۳,۷۲	PSOLA-L _{RI}	

جدول ۴- نتایج مقایسه PSO و PSO-LA برای تابع اسفیر

متوسط	بهترین	الگوریتم	ابعاد
۰,۳۳	۰,۰۰۹	PSO-Std	۱۰
۰,۰۰۲	۰,۰۰۰۴	PSO-I.W	
۰,۰۰۱	۰,۰۰۰۱	PSOLA-L _{RP}	
۰,۰۰۰۱	۹,۱۳e-۵	PSOLA-L _{RI}	
۹,۲۱	۰,۶۹	PSO-Std	۲۰
۷,۰۷	۰,۰۰۸	PSO-I.W	
۰,۰۱	۰,۰۰۶	PSOLA-L _{RP}	
۰,۰۰۲	۰,۰۰۱	PSOLA-L _{RI}	
۱۵,۰۸	۱,۱۱	PSO-Std	۳۰
۵,۸۲	۰,۰۲	PSO-I.W	
۰,۰۱	۰,۰۰۸	PSOLA-L _{RP}	
۰,۰۰۹	۰,۰۰۵	PSOLA-L _{RI}	

آزمایشات بر روی چهار تابع استاندارد صورت گرفته است که عمولاً به عنوان معیار سنجش الگوریتمهای بهینه سازی مورد استفاده قرار می‌گیرند. توابع استفاده شده عبارتند از تابع آکلی، روزنبراک، رستریجین و اسپیر که به ترتیب توسط معادلات (۸) تا (۱۱) تعریف شده‌اند. این توابع همگی دارای بهینه سراسری با مقدار ۰ هستند.

آزمایشات با مقادیر n برابر با ۱۰، ۲۰ و ۳۰ صورت گرفته است و پارامتر c_{imp} برابر با ۷۵ قرار داده شده است. تعداد جمعیت و تعداد گامها به ترتیب ۲۵ و ۱۰۰ در نظر گرفته شده‌اند. ضرایب پاداش و جریمه برای اتماتای یادگیر L_{RP} و نیز ضریب پاداش در اتماتای یادگیر L_{RI} برابر با ۰,۰۱ در نظر گرفته شده است. آزمایشات ۳۰ بار تکرار شده‌اند و بهترین و میانگین نتایج سی بار اجرا ارائه شده است.

$$f(x) = 20 + e - 20 e^{-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}} - e^{\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)} \quad (8)$$

$$f(x) = \sum_{i=1}^{n-1} (100 (x_{i+1} - x_i^2)^2 + (x_i - 1)^2) \quad (9)$$

$$f(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10) \quad (10)$$

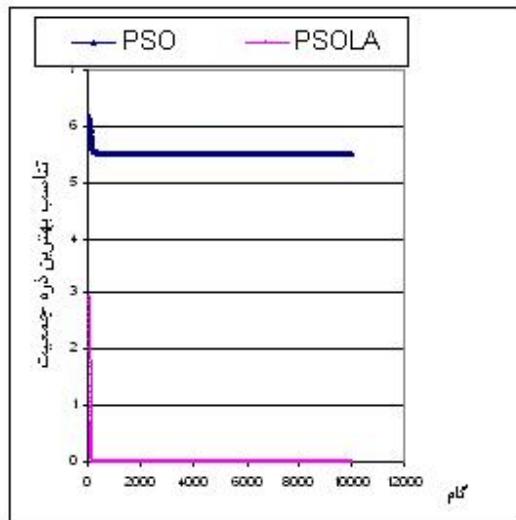
$$f(x) = \sum_{i=1}^n x_i^2 \quad (11)$$

جدولهای ۱ تا ۴، نتایج بدست آمده با استفاده از الگوریتم PSO استاندارد، PSO با وزن میانی، PSO-LA با اتماتون یادگیر L_{RI} و PSO-LA با اتماتون یادگیر L_{RP} را نشان میدهند. در این جداول، توانایی چهار الگوریتم مذکور در بهینه سازی توابع (۸) تا (۱۱) مقایسه شده است.

جدول ۱- نتایج مقایسه PSO-LA و PSO برای تابع آکلی

متوسط	بهترین	الگوریتم	ابعاد
۲,۵	۰,۵۹	PSO-Std	۱۰
۲,۴۹	۰,۰۸	PSO-I.W**	
۱,۷۸	۰,۰۱	PSOLA-L _{RP}	
۱,۵۹	۰,۰۱	PSOLA-L _{RI}	
۶,۰۹	۴,۳۲	PSO-Std	۲۰
۵,۳۶	۳,۷۶	PSO-I.W	
۴,۸۷	۲,۵۸	PSOLA-L _{RP}	
۴,۷۹	۲,۵۸	PSOLA-L _{RI}	
۹,۱۱	۷,۴۶	PSO-Std	۳۰
۸,۳۴	۶,۵۱	PSO-I.W	
۷,۷۷	۶,۲۷	PSOLA-L _{RP}	
۷,۶۴	۶,۱۵	PSOLA-L _{RI}	

** منظور از PSO-I.W، الگوریتم PSO با بکارگیری وزن میانی است.



شکل (۶) : نمودار تغییرات بهترین مقدار قناسب ذرات جمعیت برای الگوریتمهای PSO استاندارد و PSOLA-L_{RI} با تابع اسفیر بعد ۳۰

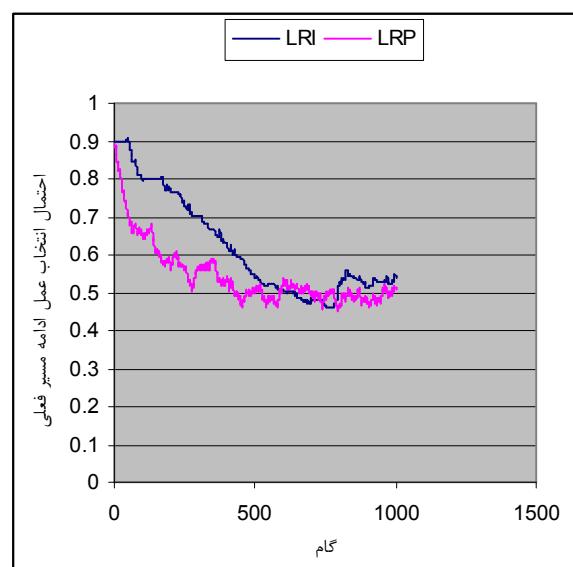
۶- نتیجه گیری

در این مقاله یک مدل جدید برای بهینه سازی بر پایه دو مدل حرکت دسته جمعی ذرات و اتوماتاهای یادگیر پیشنهاد گردید. در مدل پیشنهادی جمعیت به یک اتوماتای یادگیر مجہز میباشد که به مثابه مغز منفکر و کنترل کننده حرکات ذرات عمل میکند. اتوماتای یادگیر دارای دو عمل دنبال کردن بهترینها و یا ادامه مسیر فعلی میباشد. با انتخاب یک عمل توسط اتوماتای یادگیر در هر گام، نحوه بروز رسانی سرعت ذرات در ان گام تعیین میشود. نتایج شبیه سازیها نشان داد که مدل ارائه شده جوابهایی بهتری در مقایسه با مدل PSO استاندارد و همچنین مدل PSO که از پارامتر وزن میانی استفاده میکند تولید مینماید.

مراجع

- [1] Kennedy, J. and Eberhart, R.C., "Particle Swarm Optimization", Proceedings of IEEE International Conference on Neural Networks, Piscataway, NJ, pp. 1942-1948, 1995.
- [2] Kennedy, J. and Eberhart, R. C., "A Discrete Binary Version of the Particle Swarm Algorithm", Proceedings of the International Conference on Systems, Man, and Cybernetics, IEEE Service Center, Piscataway, NJ, pp. 4104-4108, 1997.
- [3] Narendra K. S. and Thathachar M. A. L., Learning Automata: An Introduction, Prentice Hall, 1989.
- [4] Thathachar, M.A.L. and Sastry, P.S., "Varieties of Learning Automata: An Overview", IEEE Transaction on Systems, Man, and Cybernetics-Part B: Cybernetics, Vol. 32, No. 6, pp. 711-722, 2002.

نتایج جداول (۱) تا (۴) نشان میدهد که الگوریتم عملکرد بهتری در مقایسه با الگوریتم حرکت دسته جمعی ذرات حتی زمانیکه از وزن میانی استفاده میکند داشته است. این برتری مخصوصا در مورد توابع روزنبرگ و اسفیر کاملاً محسوس است. شکل (۵)، نمودار تغییرات احتمال انتخاب عمل «ادامه مسیر فعلی» را برای بهترین اجراهای PSOLA-L_{RI} و PSOLA-L_{RP} بر روی تابع اسفیر با ۳۰ نشان میدهد. با مشاهده این شکل و اطلاعات جدول (۴) ملاحظه میشود که نوع اتوماتای یادگیر تاثیر بسزایی در تغییرات احتمال اعمال و در نتیجه، در حاصل کار دارد. این که کدام اتوماتای یادگیر جواب بهتری تولید میکند به مساله و شکل فضای جستجو بستگی دارد. شکل (۶) نموداری مقایسه ای از تغییرات بهترین مقدار تناسب ذرات جمعیت هنگام بکار گیری الگوریتمهای PSO استاندارد و PSO-LA-L_{RI} بر روی تابع اسفیر با بعد ۳۰ را نشان میدهد.



شکل (۵) : نمودار تغییرات احتمال انتخاب عمل "ادامه مسیر فعلی" در بهترین اجراهای PSOLA-L_{RI} و PSOLA-L_{RP} با تابع اسفیر بعد ۳۰

-
- 1 Particle Swarm Optimization (PSO)
 - 2 Mutation
 - 3 Genetic Algorithms
 - 4 Hill Climbing
 - 5 Simulated Annealing
 - 6 Learning Automata

- [5] Shi, Y. and Eberhart, R. C., "A Modified Particle Swarm Optimizer", IEEE International Conference on Evolutionary Computation, Anchorage, Alaska, USA, 1998.
- [6] Hagashi, N. and Iba, H., "Particle Swarm Optimization with Gaussian Mutation" Proceedings of the IEE swarm intelligence symposium, Indianapolis, Indiana, USA, pp. 72-79, 2003.
- [7] Secrest, B. R. and Lamont, G.B., "Visualizing Particle Swarm Optimization – Gaussian Particle Swarm Optimization", Proceedings of the IEEE Swarm intelligence Symposium, Indianapolis, Indiana, USA, pp. 198-204, 2003.
- [8] Stacey, A., Jancic, M., and Grundy, I., "Particle Swarm Optimization with Mutation", Proceedings of the Congress on Evolutionary Computation, p.1425-1430, 2003.
- [9] Riget, J. and Vesterstroem, J.S., "A Diversity Guided particle Swarm Optimizer - the ARPSO", Department of Computer Science, University of Aarhus, Tech. Rep.No. 2002-02, 2002.
- [10] Kiink, T., Vesterstroem, J. S. and Riget, J., "Particle Swarm Optimization with Spatial Particle Extension", Proceedings of the IEEE Congress on Evolutionary Computation, pp. 1474-1479, 2002.
- [11] Krink, T. and Lovbjerg, M., "The Life Cycle Model: Combining Particle Swarm Optimization, Genetic Algorithms and Hill Climbers" Proceedings of Parallel Problem Solving from Nature VII (PPSN 2002), pp. 621-630, 2002.
- [12] Rastegar, R., Meybodi, M. R. and Badie, K. "A New Discrete Binary Particle Swarm Optimization based on Learning Automata", Proceedings of the International Conference on Machine Learning and Applications, ICMLA '04, pp. 456-462, 2004.
- [13] Shi, Y. and Eherhart, R. C., "Empirical Study of Particle Swarm Optimization", Proceedings of the IEEE Congress 011 Evolutionary Computation, pp. 1945-1950, 1999.
- [14] Meybodi, M. R. and Beigy, H., "A Note on Learning Automata Based Schemes for Adaptation of BP Parameters", Journal of Neurocomputing, Vol. 48, No. 4, pp. 957-974, October 2002.
- [15] Beigy, H. and Meybodi, M. R., "A Learning Automata Based Algorithm for Determination of Minimum Number of Hidden Units for Three Layers Neural Networks", Journal of Amirkabir, Vol. 12, No. 46, pp. 111-136, 2001.
- [16] Munetomi, M., Takai, Y., and Sato, Y., "StGA: An Application of Genetic Algorithm to Stochastic Learning Automata", Syst. Comput. Jpn., Vol. 27, PP. 68-78, 1996.
- [17] Howell, M. N., Gordon, T. J., and Brandao, F. V., "Genetic Learning Automata for Function Optimization", IEEE Transaction on Systems, Man, and Cybernetics-Part B: Cybernetics, Vol. 32, No. 6, 2002.
- [18] Wang, X. H. and Li, J. J., "Hybrid Particle Swarm Optimization with Simulated Annealing", Proceedings of the Third International Conference on Machine Learning and Cybernetics, Shanghai, China, 2004.