

# بهبود عملکرد الگوریتم خوشه‌یابی خودکار تصاویر رنگی به کمک پیش‌پردازش با شبکه عصبی خودسازمانده (SOM)

علیرضا سردار<sup>۱</sup>، دانشجوی دکتری؛ رمضان هاوَنگی<sup>۲</sup>، استادیار

۱- دانشکده مهندسی برق و کامپیوتر - دانشگاه بیرجند - بیرجند - ایران - sardar@birjanad.ac.ir

۲- دانشکده مهندسی برق و کامپیوتر - دانشگاه بیرجند - بیرجند - ایران - havangi@birjanad.ac.ir

**چکیده:** با توجه به کاربرد فراوان مسئله خوشه‌یابی داده‌ها به‌عنوان یکی از مسائل مهم در مبحث بازشناسی الگو، زمینه‌های تحقیقاتی متنوعی از جمله خوشه‌یابی تصاویر به این موضوع اختصاص یافته است. اکثر روش‌های مطرح‌شده برای حل مسئله خوشه‌یابی تصاویر، مبتنی بر الگوریتم‌های هوش جمعی می‌باشد. با توجه به حجم بالای داده ورودی در این الگوریتم‌ها (برابر تعداد پیکسل‌های تصویر)، زمان محاسباتی زیادی صرف حل مسئله می‌شود به‌طوری‌که برای هر عضو جمعیت و به تعداد تکرار الگوریتم، برای تمام داده‌های ورودی باید هزینه خوشه‌یابی پیشنهادشده توسط هر عضو محاسبه شود. نویسنده در سال ۱۳۹۱ یک الگوریتم خوشه‌یابی نظارت‌نشده را به‌منظور خوشه‌یابی تصاویر رنگی، با استفاده از الگوریتم جستجوی گرانشی بهبودیافته معرفی کرده است. در این مقاله با توجه به عملکرد مناسب شبکه عصبی نگاشت‌های خودسازمانده (SOM)، سعی شده است ابتدا روی تمام داده‌های ورودی، توسط این شبکه، یک خوشه‌یابی اولیه انجام شود و پس از کاهش حجم داده‌های ورودی، به تعداد نرون‌های خروجی شبکه عصبی SOM، این تعداد داده محدود، به‌عنوان داده‌های ورودی الگوریتم، جهت خوشه‌یابی نهایی و تعیین خودکار تعداد خوشه‌های تصویر، مورد استفاده قرار گیرد. از طرفی با توجه به کاهش فوق‌العاده تعداد داده ورودی، دیگر در الگوریتم هوش جمعی، جمعیتی با تعداد اعضای زیاد و همچنین تعداد تکرار بالا مورد نیاز نیست که این خود سرعت مضاعف الگوریتم را به دنبال دارد. نتایج انجام‌شده برای تعدادی تصویر نشان می‌دهد که در روش جدید، ضمن حفظ نسبی نتایج به‌دست‌آمده قبلی، برای بعضی تصاویر، بهبود مقدار برازندگی را نیز شاهد هستیم.

**واژه‌های کلیدی:** خوشه‌یابی نظارت‌نشده، هوش جمعی، الگوریتم جستجوگر گرانشی بهبودیافته، شبکه عصبی SOM، ناحیه‌بندی تصویر.

## Performance Improvement of Automatic Clustering Algorithm of Colored Images through Preprocessing using Self-Organizing Maps (SOM) Neural Network

A. R. Sardar<sup>1</sup>, PhD Student; R. Havangi<sup>2</sup>, Assistant Professor

1- Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Iran, Email: sardar@birjand.ac.ir

2- Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Iran, Email: havangi@birjand.ac.ir

**Abstract:** According to the abundant application of data clustering as an important approach in pattern recognition, many researches such as image clustering have been done in this field. Most of the suggested solutions for image clustering are based on swarm intelligence algorithm. Big amount of input data in these algorithms leads to an excessive amount of computational time in a way that for each member of the population and also for each iteration of the algorithm the cost of clustering should be considered per all the imported data. In 2012, the author proposed an unsupervised algorithm using improved gravitational search algorithm to cluster colored images. According to the suitable performance of SOM neural networks, this paper firstly, tries to perform a primary clustering on all inputs to decrease the amount of input data to the number of output neurons of SOM neural network as input of the proposed algorithm to make final clustering and automatic determining of the number of the image clusters. The lesser amount of input data causes the higher performance of the algorithm. The results show that not only the previous results are relevantly kept in the new approach, but also the fitness value for some images is improved.

**Keywords:** Unsupervised clustering, swarm intelligence, improved gravitational search algorithm, SOM neural network, image segmentation.

تاریخ ارسال مقاله: ۱۳۹۵/۰۴/۰۶

تاریخ اصلاح مقاله: ۱۳۹۵/۰۶/۱۳

تاریخ پذیرش مقاله: ۱۳۹۵/۰۸/۱۳

نام نویسنده مسئول: رمضان هاوَنگی

نشانی نویسنده مسئول: ایران - بیرجند - انتهای بلوار دانشگاه - پردیس دانشگاه بیرجند - دانشکده مهندسی برق و کامپیوتر.


## ۱- مقدمه

نظارت‌نشده، جهت انجام خوشه‌یابی نهایی و تعیین تعداد مناسب خوشه‌ها به کار رود.

در این مقاله ضمن معرفی مختصر شبکه عصبی SOM [۲۷] که در بخش (۲) آمده است در بخش‌های (۳) و (۴) توضیحاتی در خصوص الگوریتم جستجوی گرانشی سیاره‌ها و سیاه‌چاله‌ها و نحوه عملکرد الگوریتم خوشه‌یابی نظارت‌نشده با استفاده از آن آمده است. در بخش (۵) ضمن توضیحات مختصر راجع به مسئله ناحیه‌بندی تصویر، ایده پیشنهادی جهت کاهش حجم داده‌های ورودی الگوریتم خوشه‌یابی بر روی تعدادی از تصاویر مرجع اعمال شده و نتایج به‌دست‌آمده ارائه شده است. همچنین روش پیشنهادی با نتایج روش بخش‌بندی نظارت‌نشده سلسله مراتبی تصاویر [۳۰] مقایسه شده است. در بخش نتایج نیز روش پیشنهادی مورد بحث قرار گرفته است.

## ۲- شبکه عصبی خودسامانده (SOM)

شبکه عصبی خودسامانده (SOM) [۲۷] یک شبکه عصبی بدون ناظر است که به دلیل عملکرد مناسب آن، در کاربردهای زیادی از جمله خوشه‌یابی داده و تصویر به کار رفته است. این شبکه همان‌طور که در شکل (۱) نشان داده شده است، شامل دو لایه می‌شود، لایه اول که همان لایه ورودی است و داده‌های ورودی توسط آن به لایه دوم یا لایه خروجی منتقل می‌شود.



شکل ۱: ساختار شبکه عصبی SOM با لایه خروجی دوبعدی

داده‌های ورودی می‌تواند شامل  $n$  بعد باشد و هر داده به تمام نرون‌های لایه خروجی که یک شبکه نرونی مسطح  $v \times v$  است، منتقل می‌شود. به خاطر ساختار مسطح لایه خروجی، هر نرون با آدرس سطر و ستون  $ij$  شناخته می‌شود که  $i, j = 1, 2, \dots, v$  و همچنین هر نرون دارای بردار وزنی با ابعاد برابر با ابعاد داده ورودی است  $w_{1,ij}, w_{2,ij}, \dots, w_{n,ij}$

اساس عملکرد این نوع شبکه عصبی به این صورت است که ابتدا، ساختار شبکه یعنی تعداد نرون‌های لایه ورودی و خروجی، توسط طراح بر اساس ابعاد داده ورودی و شکل خروجی مسئله انتخاب

خوشه‌یابی داده‌ها یک امر مهم در مبحث داده‌کاوی است. هدف از خوشه‌یابی این است که از بین یکسری داده‌های ورودی، آن‌هایی که از نظر یک تعداد ویژگی خاص، شباهت بیشتری دارند، در یک خوشه قرار بگیرند. به این ترتیب داده‌هایی که در یک خوشه قرار دارند بیشترین شباهت را به یکدیگر دارند و داده‌های موجود در خوشه‌های متفاوت از یکدیگر متمایز هستند.

به طور کلی الگوریتم‌های خوشه‌یابی از نظر تعیین تعداد خوشه‌ها به دو دسته خوشه‌یابی نظارت‌شده<sup>۱</sup> و خوشه‌یابی نظارت‌نشده<sup>۲</sup> تقسیم می‌شوند، در خوشه‌یابی نظارت‌شده، نیاز است تا تعداد بهینه خوشه‌ها از قبل توسط کاربر تعیین شود درحالی‌که در خوشه‌یابی نظارت‌نشده، تعداد بهینه خوشه‌ها توسط خود الگوریتم به‌دست می‌آید. تاکنون روش‌های مختلفی برای خوشه‌یابی پیشنهاد شده است [۳، ۴].

نویسنده در [۲۸] ضمن بررسی روش‌های متنوع مطرح‌شده از جمله الگوریتم‌های ابتکاری [۵-۷] و الگوریتم‌های هوش جمعی، با توجه به عملکرد مناسب الگوریتم‌های هوش جمعی مانند PSO<sup>۳</sup> [۱۰] و GA<sup>۴</sup> [۹] و ACO<sup>۵</sup> [۱۱]، در جستجوی بهینه فضای پاسخ، روش‌های پیشنهادی خوشه‌یابی نظارت‌شده بر اساس این الگوریتم‌ها [۱۲-۱۳] و همچنین روش‌های پیشنهادی خوشه‌یابی نظارت‌نشده مانند GCUK<sup>۶</sup> [۸] و VLIGA<sup>۷</sup> [۱۴] (با استفاده از GA)، DCP SO<sup>۸</sup> [۲] و MEPSO<sup>۹</sup> [۱۵] (با استفاده از PSO) و IAFHA<sup>۱۰</sup> [۱۶] (با استفاده از ACO) را اشاره نموده است. در ادامه ضمن معرفی الگوریتم جستجوی گرانشی (GSA<sup>۱۱</sup>) [۱۷]، نقاط ضعف این الگوریتم را مشخص نموده و با الهام از پدیده سیاه‌چاله‌ها در طبیعت، الگوریتم بهبودیافته آن را با نام الگوریتم جستجوی گرانشی سیاره‌ها و سیاه‌چاله‌ها (PABH-GSA<sup>۱۲</sup>) [۲۸] ارائه کرده است و در ادامه با الگوبرداری از الگوریتم‌های خوشه‌یابی اشاره‌شده، یک الگوریتم خوشه‌یابی نظارت‌نشده بر اساس الگوریتم جستجوگر گرانشی بهبودیافته معرفی نموده است.

هر چند الگوریتم‌های هوش جمعی، در مقایسه با سایر الگوریتم‌ها فضای پاسخ را به صورت بهینه جستجو می‌کنند، عملکرد مناسب و یکتایی محدوده پاسخ آن‌ها، کاملاً به انتخاب مناسب تابع برازندگی و ابعاد و تعداد داده ورودی وابسته است. از طرفی افزایش بیش از حد ابعاد و تعداد داده ورودی، هزینه محاسباتی زیادی را به الگوریتم تحمیل می‌کند. بنابراین کاهش حجم داده‌های ورودی می‌تواند به عنوان یک راهکار جهت افزایش کارایی الگوریتم‌های خوشه‌یابی مورد استفاده قرار بگیرد. با توجه به عملکرد مناسب شبکه عصبی SOM<sup>۱۳</sup> در مسئله خوشه‌یابی، این ایده مطرح شد که در ابتدا داده‌های ورودی یا همان اطلاعات رنگی پیکسل‌های تصویر را به یک شبکه عصبی SOM وارد نموده تا خوشه‌یابی اولیه بر روی داده‌ها، به منظور کاهش شدید تعداد آن‌ها، صورت پذیرد و در ادامه داده‌های جدید که از نظر تعداد بسیار محدود می‌باشد، به عنوان ورودی الگوریتم خوشه‌یابی

$$a_i^d(t) = G(t) \sum_{j=1}^N \left[ rand_j^d(t) M_j(t) sign_j^d(t) \right]$$

$$sign_j^d(t) = \begin{cases} \frac{x_j^d(t) - x_i^d(t)}{|x_j^d(t) - x_i^d(t)|} & \text{if } i \neq j \\ 0 & \text{if } i = j \end{cases} \quad (3)$$

$$G(t) = \exp(-\tau \times t) \quad (4)$$

$x_j^d(t)$  موقعیت ذره  $j$ ام در بعد  $d$ ام و در تکرار  $t$ ،  $a_i^d(t)$  شتاب اعمالی به ذره  $j$ ام در بعد  $d$ ام و در تکرار  $t$ ، ضریب تعیین شده توسط کاربر (انتخاب مناسب در بازه  $[0.1, 0.5]$ )،  $M_j(t)$  جرم اختصاص یافته به ذره  $j$ ام در تکرار  $t$  که تعدادی از بهترین جرم‌ها به عنوان سیاه‌چاله انتخاب و جرم آن‌ها مجدداً توسط معادله زیر به‌روزرسانی می‌شود:

$$M_j(t) = (\beta \times rand_j(t) + 1) \times M_j(t)$$

$$j \in \{\text{best 10 masses}\} \quad (5)$$

$\beta$  نیز ضریب تعیین شده توسط کاربر می‌باشد. معادلات زیر به‌روزرسانی سرعت و موقعیت هر ذره را برای تکرار بعدی نشان می‌دهد.

$$v_i^d(t+1) = rand_j \cdot v_i^d + a_i^d(t)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (6)$$

جهت توضیحات بیشتر در مورد معادلات، ضرایب و نحوه عملکرد الگوریتم، به مرجع [۲۸] مراجعه نمایید.

#### ۴- الگوریتم خوشه‌یابی نظارت‌نشده با استفاده از PABH-GSA

در تمام روش‌های خوشه‌یابی نظارت‌نشده، باید حداقل و حداکثر تعداد خوشه‌ها مشخص شود. حداقل تعداد خوشه‌ها معمولاً برابر دو خوشه و حداکثر تعداد خوشه‌ها می‌تواند به صورت تجربی (اختیاری) و یا با توجه به محدودیت‌های مسئله انتخاب شود. به منظور خوشه‌یابی با استفاده از PABH-GSA به این صورت عمل شد که موقعیت هر ذره در فضای پاسخ مسئله، نشان‌دهنده تعدادی مرکز خوشه به عنوان یک جواب خوشه‌یابی و تعدادی آستانه برای تأیید و یا عدم تأیید این مراکز خوشه است. تعداد مراکز خوشه‌ها و همچنین تعداد آستانه‌ها برابر حداکثر تعداد خوشه‌ها می‌باشد ولی برای هر ذره و در هر بار تکرار الگوریتم، تمام مراکز خوشه مورد تأیید نیستند و فقط آن‌هایی که با استفاده از مقدار آستانه مربوطه تأیید شده‌اند قابل قبول هستند.

برای درک بهتر، اگر یک مجموعه داده دارای  $d$  بعد باشد و برای آن حداکثر  $K$  مرکز خوشه در نظر گرفته شود، ابعاد فضای پاسخ مسئله

می‌شود، در ادامه وزن‌های اولیه هر نرون لایه خروجی به صورت تصادفی انتخاب شده و سپس هر یک از داده‌های ورودی به صورت تک تک به شبکه اعمال می‌شود. برای هر داده ورودی، فاصله بردار وزن هر نرون با بردار داده محاسبه می‌شود و نرونی که کمترین فاصله با داده ورودی را داشته باشد به عنوان نرون برنده انتخاب شده و بردار وزن این نرون و تعدادی از نرون‌های همسایه‌اش توسط معادله (۱) به روز می‌شود و وزن بقیه نرون‌ها نیز بدون تغییر باقی می‌ماند. در این معادله  $\alpha_k$  نرخ آموزش،  $X_k$  داده ورودی و  $N_{ij}^k$  تعداد همسایه‌های نرون برنده می‌باشد.

$$w_{ij}^{k+1} = w_{ij}^k + \alpha_k (X_k - w_{ij}^k), \quad ij \in N_{ij}^k \quad (1)$$

سپس داده بعدی وارد شبکه می‌شود و روند قبلی تا یک تعداد تکرار مشخص برای تمام داده‌ها و یا رسیدن به یک نقطه ثبات ادامه می‌یابد. در خاتمه هریک از نرون‌های خروجی، نماینده تعدادی از داده‌های ورودی خواهد بود که بر اساس کمترین فاصله به آن اختصاص یافته است.

#### ۳- الگوریتم جستجوی گرانشی سیاره‌ها و سیاه‌چاله‌ها (PABH-GSA)

الگوریتم PABH-GSA [۲۸] به منظور بهبود عملکرد و رفع نقاط ضعف الگوریتم GSA [۱۷] در همگرایی و جستجوی بهینه فضای پاسخ، توسط نویسنده معرفی شد. در الگوریتم GSA ابتدا تعداد  $N$  ذره در فضای پاسخ مسئله که می‌تواند  $D$  بعد داشته باشد به صورت تصادفی ایجاد می‌شود. سپس با توجه به موقعیت و میزان برازندگی آن‌ها (که توسط یک تابع برازندگی مشخص می‌شود) مقداری جرم به هر یک از آن‌ها تعلق می‌گیرد. در ادامه با اعمال معادلات معرفی شده، شتاب و سرعت هر جرم با الهام از نیروی جاذبه گرانشی محاسبه می‌شود و موقعیت جدید جرم‌ها در فضا تعیین می‌گردد، این عمل برای  $T$  بار تکرار الگوریتم انجام شده و در نهایت موقعیت جرم دارای بهترین برازندگی، به عنوان بهترین پاسخ الگوریتم استخراج می‌شود.

مهم‌ترین معایب GSA در مقایسه با آنچه که در GA و PSO شاهد هستیم، عدم توجه مناسب به نخبه‌گرایی و جستجوی بهینه فضای پاسخ، می‌باشد، با اعمال تغییرات انجام شده در معادله شتاب گرانشی و انتخاب درصدی از جرم‌ها (۲۰ درصد) به عنوان سیاه‌چاله‌های فضایی، این نقاط ضعف پوشش مناسبی یافت و عملکرد بسیار مناسب PABH-GSA در مقایسه با GSA برای ۲۳ تابع محک استاندارد [۱۸، ۱۲]. به خوبی نمایان شد. در ادامه معادلات مربوط به PABH-GSA آمده است.

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)}, \quad worst(t) = \max_{j \in \{1, \dots, N\}} fit_j(t)$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)}, \quad best(t) = \min_{j \in \{1, \dots, N\}} fit_j(t) \quad (2)$$

با توجه به توضیحات داده‌شده در مرجع [۲۸]، برای خوشه‌یابی نظارت‌نشده، شاخص DB معمولاً تعداد خوشه‌های بسیار کمی را نتیجه می‌دهد و بنابراین با اعمال یک ضریب، شاخص DB جدید یا  $NDB^{15}$  معرفی شد.

$$NDB = \frac{1}{(1 + \ln(n)) \times n} \sum_{i=1}^n R_{i,qt} \quad (11)$$

از آنجایی که در خوشه‌یابی نظارت‌نشده، هم به دنبال تعیین تعداد مناسب خوشه‌ها و هم تعیین مراکز بهینه خوشه‌ها هستیم یا به عبارت دیگر با یک مسئله چندهدفه روبرو هستیم. برای عملکرد بهتر الگوریتم و کاهش فضای جستجو، موقعیت مکانی هر ذره پس از تعیین داده‌های اختصاص‌یافته به آن، به میانگین آن داده‌ها تغییر می‌یابد که یک موقعیت بسیار مناسب‌تر از موقعیت قبلی است و باعث نتایج بهتر و سریع‌تر می‌شود. آزمایش‌های انجام‌شده نیز این موضوع را ثابت کرد.

با توجه به اینکه مقادیر آستانه  $T$  به‌طور تصادفی در بازه  $(1, 0)$  انتخاب می‌شود، احتمال دارد برای یک جرم هیچ کدام از آن‌ها بزرگ‌تر مساوی  $0.5$  نباشد (هیچ مرکز خوشه‌ای قابل قبول نباشد). برای رفع این مشکل با توجه به اینکه حداقل تعداد خوشه‌ها برابر دو خوشه است، از بین مقادیر آستانه، دو مقدار به‌صورت تصادفی انتخاب می‌گردد و مجدداً به‌طور تصادفی در بازه  $(0.1, 0.5)$  مقداردهی می‌شود. از طرفی در حین اجرای الگوریتم، ممکن است مقدار آستانه به مقداری بیشتر از ۱ و یا کمتر از ۰ تغییر پیدا کند. برای رفع این مشکل نیز، مقدار آستانه بیشتر از ۱ به ۱ و کمتر از ۰ به ۰ تغییر داده می‌شود.

##### ۵- ناحیه‌بندی تصویر با استفاده از الگوریتم پیشنهادی

هدف از ناحیه‌بندی تصویر، تقسیم یک تصویر به تعدادی ناحیه مختلف است که این ناحیه‌ها، اشیاء یا قسمت‌های آن‌ها را نمایش می‌دهد. ناحیه‌بندی تصویر یک روند و پایه در برخی کاربردهای پردازش تصویر و ماشین‌بینایی است و می‌توان آن را به‌عنوان اولین اقدام پردازش سطح پایین در بازشناسی الگو و پردازش تصویر در نظر گرفت. روش‌های موجود برای ناحیه‌بندی به دو دسته ناحیه‌بندی بر اساس اطلاعات ناحیه و ناحیه‌بندی بر اساس اطلاعات نقطه، تقسیم می‌شود. برای ناحیه‌بندی بر اساس اطلاعات ناحیه، روش‌های مختلفی وجود دارد که از آن جمله می‌توان به روش‌هایی مانند ناحیه‌بندی بر اساس اطلاعات بافت [۲۴]، ناحیه‌بندی بر اساس اطلاعات لبه [۲۵]، ناحیه‌بندی با استفاده تبدیل حوضچه [۲۶]، ناحیه‌بندی مبتنی بر برش نرمالیزه گراف [۲۹]، ناحیه‌بندی بر اساس روش‌های ترکیبی [۳۰] و ... اشاره کرد. در اینجا منظور از ناحیه‌بندی تصویر، ناحیه‌بندی بر اساس اطلاعات نقطه است. در این روش، شدت روشنایی یا اطلاعات رنگ هر پیکسل به‌عنوان داده ورودی جهت خوشه‌یابی در نظر گرفته می‌شود. در یک تصویر رنگی RGB، به هر پیکسل دارای یک بردار عددی ۳ بعدی است که هر بعد، مقدار روشنایی هر یک از رنگ‌های قرمز، سبز و

برابر  $K+K \times d$  می‌شود. یعنی هر ذره در فضایی با ابعاد  $K+K \times d$  سیر می‌کند که در آن  $K$  بعد اول به‌عنوان آستانه  $T$  و بقیه ابعاد به‌صورت بردارهای  $d$  بعدی به‌عنوان مراکز خوشه پیشنهادی توسط این ذره در نظر گرفته می‌شود. مقادیر  $K$  بعد اول در بازه  $[0, 1]$  است. اگر برای هر مقدار آستانه  $T \geq 0.5$  باشد، مرکز خوشه متناظر با آن در نظر گرفته می‌شود در غیر این‌صورت اگر  $T < 0.5$  باشد، مرکز خوشه متناظر با آن از لیست مراکز خوشه پیشنهادی آن ذره حذف می‌شود. به‌عنوان مثال همان‌طور که در شکل (۲) نشان داده شده است برای  $d=2$  و  $K=3$ ، هر جرم در یک فضای ۹ بعدی به‌صورت زیر سیر می‌کند. که در آن  $T_1$  آستانه مربوط به مرکز خوشه  $M_1$  می‌باشد.

|    |    |    |     |     |     |     |     |     |
|----|----|----|-----|-----|-----|-----|-----|-----|
| T1 | T2 | T3 | M11 | M12 | M21 | M22 | M31 | M32 |
|----|----|----|-----|-----|-----|-----|-----|-----|

شکل ۲: مثالی از خوشه‌یابی نظارت‌نشده

لازم به ذکر است، مرز آستانه  $T=0.5$  به‌دلیل حفظ ماهیت تصادفی الگوریتم انتخاب‌شده است تا فعال یا غیرفعال بودن یک خوشه از شانس مساوی برخوردار باشد و هیچ اعمال شرطی به مسئله انجام نشود. با توجه به ابعاد انتخاب‌شده، هر ذره در هر بار تکرار الگوریتم، توسط یک تابع برازندگی ارزیابی می‌شود و در نهایت پس از پایان تعداد تکرار مشخص، ذره دارای بهترین برازندگی، همزمان تعداد بهینه خوشه‌ها و مراکز آن‌ها را مشخص می‌کند.

همان‌طور که گفته شد برای ارزیابی هر ذره به یک تابع برازندگی نیاز است. تاکنون توابع (شاخص‌های) مختلفی چه برای خوشه‌یابی فازی [۲۰-۲۱] و یا غیر فازی [۱۹، ۲۲] ارائه شده است. یکی از معروف‌ترین شاخص‌ها، شاخص  $DB^{14}$  [۱۹] است که معادلات (۷) تا (۱۰) نحوه به‌دست آوردن  $DB$  را نشان می‌دهد.

$$S_{i,q} = \left( \frac{1}{|C_i|} \sum_{x \in C_i} \|x - m_i\|_2^q \right)^{1/q} \quad (7)$$

$$d_{ij,t} = \left( \sum_{s=1}^p |m_{si} - m_{sj}|^t \right)^{1/t} = \|m_i - m_j\|_t \quad (8)$$

$$R_{i,qt} = \max_{i \neq j} \left( \frac{S_{i,q} + S_{j,q}}{d_{ij,t}} \right) \quad (9)$$

$$DB = \frac{1}{n} \sum_{i=1}^n R_{i,qt} \quad (10)$$

$S_{i,q}$  تعیین‌کننده میزان پراکندگی داده‌های درون خوشه  $i$  نسبت به بردار مرکز خوشه  $m_i$ ،  $|C_i|$  برابر تعداد داده‌های اختصاص‌یافته به خوشه  $i$  و  $m_i$  از برابر میانگین این داده‌ها می‌باشد.  $d_{ij,t}$  برابر فاصله بین دو بردار مرکز خوشه  $i$  و  $j$  است که هر کدام دارای  $p$  بعد می‌باشد و  $n$  نیز برابر تعداد خوشه‌ها است.  $q, t \geq 1$  و  $q$  یک عدد صحیح است.  $q, t$  می‌تواند مستقل از یکدیگر تعریف شود.

انجام شده مناسب بود، ولی باز هم تعداد داده ورودی به الگوریتم، برابر ۲۵۶۰۰ داده است که به عنوان مثال برای یک جمعیت با ۵۰ عضو و ۱۰۰ بار تکرار الگوریتم، محاسبه میزان برازندگی خوشه‌یابی پیشنهاد شده توسط هر عضو برای تمام ۲۵۶۰۰ داده به دفعات ۵۰۰۰ مرتبه باید تکرار شود که این زمان محاسباتی زیادی را تلف می‌کند. لذا با توجه به محاسبات بسیار مختصر خوشه‌یابی تصاویر سطح خاکستری، این ایده مطرح شده که خوشه‌یابی در دو مرحله اجرا شود، مرحله اول خوشه‌یابی جهت کاهش تعداد رنگ‌ها و مرحله دوم ناحیه‌بندی خودکار تصویر با تعداد محدود رنگ به دست آمده که به عنوان ورودی الگوریتم استفاده می‌شود.

با توجه به عملکرد مناسب شبکه عصبی SOM و استفاده از آن در کاربردهای خوشه‌یابی نظارت شده، در این مقاله، از شبکه عصبی SOM به عنوان پیش‌پردازش تصاویر ورودی، جهت کاهش تعداد رنگ‌های تصویر و در نتیجه کاهش تعداد داده‌های ورودی به الگوریتم اصلی، استفاده شده است. جهت بررسی بهتر، شبکه عصبی SOM با تعداد نرون‌های مختلف  $7 \times 7$ ،  $8 \times 8$ ،  $9 \times 9$  و  $10 \times 10$  به کار رفت که به ترتیب تعداد داده‌های ورودی به الگوریتم را به ۴۹، ۶۴، ۸۱ و ۱۰۰ داده کاهش می‌دهد. شکل (۳) خوشه‌یابی انجام شده توسط شبکه SOM با تعداد نرون‌های اشاره شده را نشان می‌دهد.



شکل ۳: کاهش تعداد رنگ تصویر، توسط شبکه SOM به تعداد نرون‌های خروجی شبکه، به ترتیب از چپ به راست، ۴۹، ۶۴، ۸۱ و ۱۰۰ رنگ

نحوه عملکرد روش پیشنهادی همان‌طور که در شکل (۴) مشخص شده، به این صورت است که در ابتدا، تصویر ورودی مانند شکل (۵) به یک تصویر با ابعاد  $160 \times 160$  مطابق شکل (۶) تغییر داده شده و سپس تصویر جدید به دست آمده مانند شکل (۷) به فضای رنگ Lab انتقال داده می‌شود و داده‌های لایه a و b به عنوان ورودی به شبکه عصبی SOM اعمال می‌شود، پس از آموزش شبکه، داده‌های ورودی (۲۵۶۰۰ داده) بین نرون‌های خروجی شبکه SOM تقسیم می‌شوند. در ادامه، میانگین داده‌های متعلق به هر نرون محاسبه شده و به عنوان داده‌های ورودی الگوریتم خوشه‌یابی خودکار مورد استفاده قرار می‌گیرد، همان‌طور که ملاحظه می‌شود، تعداد داده‌های ورودی به الگوریتم به میزان تعداد نرون‌های خروجی کاهش می‌یابد. مثلاً برای شبکه SOM با ۶۴ نرون خروجی، تعداد داده‌های ورودی به الگوریتم از ۲۵۶۰۰ داده به ۶۴ کاهش می‌یابد. از طرفی با توجه به تعداد ورودی محدود وارد شده به الگوریتم هوش جمعی، دیگر نیاز به جمعیتی با تعداد اعضاء و تعداد تکرار زیاد نیست. البته هزینه محاسباتی آموزش

آبی را نشان می‌دهد. به ازای مقادیر مختلف اختصاص یافته به هر یک از این سه رنگ اصلی، رنگ‌های مختلف به وجود می‌آید و به این ترتیب می‌توان رنگ هر پیکسل را مشخص کرد. حال اگر اطلاعات رنگی یک پیکسل به عنوان یک مرکز خوشه سه‌بعدی در نظر گرفته شود، با استفاده از خوشه‌یابی می‌توان بردارهای رنگی که در فاصله نزدیکی از این مرکز خوشه قرار دارند را درون یک خوشه قرار داد. به عبارت دیگر، با استفاده از خوشه‌یابی می‌توان یک تصویر را بر اساس اطلاعات رنگ آن ناحیه‌بندی کرد.

در فضای رنگ RGB به ازای تغییرات در هریک از رنگ‌های اصلی، شدت روشنایی رنگ به دست آمده نیز تغییر می‌کند. بنابراین امکان دارد برای دو پیکسل که دارای یک رنگ هستند، به دلیل اینکه یکی دارای شدت روشنایی بیشتری است، پس از خوشه‌یابی در دو خوشه مجزا قرار بگیرند. بنابراین برای ناحیه‌بندی تصویر بر اساس رنگ، معمولاً فضای رنگی RGB مورد استفاده قرار نمی‌گیرد و از این فضای رنگ صرفاً به منظور کوانتیزه‌سازی (فشرده‌سازی) تصویر استفاده می‌شود. فضاهای رنگ دیگری مانند HSV و Lab وجود دارد که در آن‌ها بین شدت روشنایی رنگ‌ها و اطلاعات رنگی تمایز ایجاد شده است. برای ناحیه‌بندی بر اساس رنگ معمولاً از این گونه فضاهای رنگی استفاده می‌شود و در خوشه‌یابی فقط اطلاعات رنگی مورد استفاده قرار می‌گیرد و از اطلاعات شدت روشنایی رنگ‌ها هیچ گونه استفاده‌ای نمی‌شود. با توجه با این که اطلاعات رنگی در فضای رنگی Lab نسبت به سایر فضاهای رنگ، از همواری بیشتری برخوردار است، در الگوریتم پیشنهادی از فضای رنگی Lab استفاده شده است.

در فضای رنگی Lab، لایه L، تعیین کننده مقدار شدت روشنایی. لایه a اطلاعات رنگ‌های ترکیبی سبز و مگنتا و لایه b، اطلاعات رنگ‌های ترکیبی آبی و زرد را مشخص می‌کند. برای ناحیه‌بندی بر اساس رنگ، فقط لایه‌های a و b مورد استفاده قرار می‌گیرد.

خوشه‌یابی تصاویر رنگی، نسبت به تصاویر سطح خاکستری زمان محاسباتی بسیار زیادی را تلف می‌کند. در خوشه‌یابی تصاویر سطح خاکستری، با فرض اطلاعات ۸ بیتی هر پیکسل، مقدار شدت روشنایی هر پیکسل تصویر بدون توجه به ابعاد آن، عددی بین ۰ تا ۲۵۵ خواهد بود، بنابراین به جای خوشه‌یابی پیکسل‌ها، می‌توان سطوح روشنایی را خوشه‌یابی کرد که حداکثر شامل ۲۵۶ داده ورودی می‌شود. ولی به منظور اقدام مشابه برای تصاویر رنگی حتی با کاهش ابعاد فضای رنگی، (به عنوان مثال در فضای Lab به ۲ بعد نسبت به فضای ۳ بعدی RGB) تعداد رنگ‌ها  $256 \times 256$  رنگ خواهد بود، بنابراین برای تصاویر با تعداد پیکسل بسیار بیشتر از این تعداد رنگ، خوشه‌یابی رنگ‌ها نسبت به خوشه‌یابی پیکسل‌ها مقرون به صرفه خواهد بود در غیر این صورت بهتر است خوشه‌یابی بر روی همان پیکسل‌ها انجام شود.

در مرجع [۲۸]، پیشنهاد شد جهت کاهش هزینه محاسباتی، اندازه تمام تصاویر ورودی، به ابعاد  $160 \times 160$  پیکسل کاهش یابد، کاهش بیشتر ابعاد، دقت ناحیه‌بندی تصویر را کاهش می‌دهد. هر چند اقدام

در الگوریتم هوش جمعی، معادلات شتاب، سرعت و موقعیت مکانی برای هریک از ۹ بعد مسئله و برای هر ۵۰ جرم و در هر بار از ۱۰۰ مرتبه تکرار الگوریتم باید به‌روزرسانی شود، هریک از جرم‌ها هم به‌صورت جداگانه و در هر بار تکرار الگوریتم باید به‌روزرسانی شود ضمن اینکه برای افزایش دقت الگوریتم موقعیت هر یک از اجرام در هر بار تکرار الگوریتم از میانگین‌گیری هریک از خوشه‌ها (از مجموع ۲۵۶۰۰ داده که حاصل تصویر ۱۶۰ در ۱۶۰ پیکسل است و بین مراکز خوشه پیشنهادی توسط هر جرم تقسیم شده است) به‌دست می‌آید. در شبکه عصبی SOM نیز پس از اعمال هر ورودی، وزن نرون برنده و  $n$  همسایگی آن به‌روز می‌شود و این کار به تعداد ورودی‌ها و در هر بار تکرار الگوریتم تکرار می‌شود که اگر عدد  $n$  بزرگ انتخاب شود محاسبات شبکه عصبی بیشتر هم خواهد بود. منتهی عاملی که بار محاسباتی بسیار زیادی به الگوریتم هوش جمعی وارد می‌کند محاسبه شاخص DB است که کاربرد فراوانی در خوشه‌یابی نظارت‌نشده دارد.

همان‌طور که در معادلات مربوط به این شاخص در بخش (۴) مقاله اشاره شده است، در معادله (۷) نیاز است تا مجموع فاصله‌های بین هر دو عضو در هر خوشه محاسبه شود و در صورت حجم زیاد داده ورودی و افزایش تعداد داده‌های اختصاص‌یافته به هر خوشه، محاسبات بسیار حجیم خواهد بود، برای ۲۵۶۰۰ داده ورودی، بهترین حالت جهت کاهش محاسبات این است که تمام مراکز خوشه‌ها (مثلاً برای تصاویر داده‌شده ۵ خوشه) فعال باشند و داده‌ها به‌طور مساوی بین خوشه‌ها تقسیم شود تا حداکثر داده‌های اختصاص‌یافته به هر خوشه برای تصاویر داده‌شده، برابر یک‌پنجم کل داده‌ها یا ۵۱۲۰ داده (کمترین مقدار ماکزیمم ممکن داده در هر خوشه) باشد که با این مقدار باید برای هر یک از ۵ خوشه فاصله بین  $5120 \times 5120 = 26214400$  محاسبه گردد که برای ۵ خوشه عدد ۱۳۱۰۴۶۴۰ به‌دست می‌آید و میانگین تمام این فاصله در هر خوشه نیز باید محاسبه شود و این محاسبات برای هر یک از جرم‌ها (۵۰ جرم) و در هر بار تکرار الگوریتم (۱۰۰ بار) انجام می‌شود، در صورتی که در شبکه عصبی برای تعیین نرون برنده، کافی است فاصله هریک از ۲۵۶۰۰ داده با ۶۴ نرون خروجی در ۱۰۰ بار تکرار انجام شود و همان‌طور که در جدول (۱) دیده می‌شود محاسبات تعیین اختصاص داده به یک خوشه در الگوریتم هوش مصنوعی ۲۰۰۰ برابر بیشتر از شبکه عصبی SOM است. حال خروجی شبکه عصبی SOM فقط ۶۴ داده خواهد بود و اعمال این ۶۴ داده به الگوریتم هوش جمعی جهت خوشه‌یابی نهایی، هزینه محاسباتی بسیار پایین‌تری خواهد داشت.

روش جدید پیشنهادشده برای ۵ تصویر مرجع [۲۳] مورد آزمایش قرار گرفت که برای هر تصویر ۴ شبکه SOM به‌صورت مجزا و با تعداد نرون‌های اشاره‌شده استفاده شد. داده‌های خروجی شبکه SOM به‌عنوان داده‌های ورودی الگوریتم خوشه‌یابی نظارت‌نشده به کار رفت که در آن تعداد حداکثر خوشه‌ها برابر ۵ خوشه،  $\tau = 0.02$  و با توجه به کاهش تعداد داده‌های ورودی، تعداد جرم‌ها برابر ۲۰ جرم انتخاب شد

شبکه SOM به مسئله اضافه شده است ولی این هزینه باعث کاهش بسیار زیاد هزینه محاسباتی شاخص NDB شده است. با توجه به اینکه مقایسه زمان اجرا که وابستگی شدیدی به سخت‌افزار و نحوه کدنویسی هر یک از روش‌ها دارد ملاک درستی برای مقایسه نیست، جهت درک بهتر مسئله، توضیحاتی راجع به میزان محاسبات هریک از روش‌ها در ادامه آمده است.




شکل ۴: بلاک دیاگرام روش پیشنهادی




شکل ۵: تصویر اولیه



شکل ۶: تغییر ابعاد تصویر، به ابعاد جدید ۱۶۰×۱۶۰



شکل ۷: انتقال تصویر به فضای رنگ Lab (به ترتیب از چپ به راست تصویر اول مربوط به L، دوم a و سوم b)



شکل ۱۲: نتایج ناحیه‌بندی تصویر خروجی شبکه SOM با ۶۴ رنگ



شکل ۱۳: تصویر دست و خروجی شبکه SOM با ۶۴ نرون خروجی



شکل ۱۴: نتایج ناحیه‌بندی تصویر خروجی شبکه SOM با ۶۴ رنگ



شکل ۱۵: تصویر اسب و خروجی شبکه SOM با ۶۴ نرون خروجی



شکل ۱۶: نتایج ناحیه‌بندی تصویر خروجی شبکه SOM با ۶۴ رنگ

جدول (۲) نتایج شاخص برازندگی NDB و تعداد K خوشه به‌دست‌آمده از خوشه‌یابی تصاویر ورودی، به ازای الگوریتم پیشنهادی جدید و الگوریتم قبلی را نشان می‌دهد.

با توجه به این جدول و تصاویر به‌دست‌آمده مشخص می‌شود که در روش جدید خوشه‌یابی، نتایج برازندگی به‌دست‌آمده بسیار نزدیک بوده و برای دو تصویر کوه و فیل نتایج بهتر هم شده است. تصاویر به‌دست‌آمده نیز عملکرد مناسب این روش را تأیید می‌کند.

در ادامه الگوریتم پیشنهادی با الگوریتم بخش‌بندی نظارت‌نشده سلسله مراتبی تصاویر [۳۰] برای دو تصویر طبیعت مقایسه شده است. در الگوریتم معرفی‌شده از اطلاعات لبه و شدت روشنایی جهت ناحیه‌بندی تصاویر استفاده شده است. شکل‌های (۱۷) الی (۲۰) نتیجه ناحیه‌بندی این دو تصویر را با روش پیشنهادی نشان می‌دهد. در اینجا از شبکه عصبی SOM

و الگوریتم برای ۵۰ مرتبه تکرار اجرا گردید. شکل‌های (۸) تا (۱۶)، نتایج ناحیه‌بندی انجام‌شده توسط روش جدید پیشنهادی را نمایش می‌دهد. البته با توجه به اینکه برای هر تصویر، آزمایش با ۴ شبکه عصبی SOM با تعداد نرون‌های متفاوت انجام شده است، به‌طور خلاصه، فقط تصاویر مربوط به آزمایش با شبکه عصبی SOM با ۶۴ نرون خروجی نمایش داده شده است و تمامی نتایج به‌صورت کلی در جدول (۲) مشخص شده است.

جدول ۱: مقایسه تعداد محاسبات لازم جهت تعیین فاصله داده‌ها، به‌منظور تشخیص اختصاص مناسب هر داده به خوشه متناظر


| الگوریتم               | روش قبلی    | روش پیشنهادی |           |
|------------------------|-------------|--------------|-----------|
|                        | PABH-GSA    | SOM          |           |
| تعداد داده             | ۲۵۶۰۰       | ۶۴           | ۲۵۶۰۰     |
| تعداد اعضاء            | ۵۰ جرم      | ۲۰ جرم       | ۶۴ نرون   |
| تعداد تکرار            | ۱۰۰         | ۵۰           | ۱۰۰       |
| تعداد کل محاسبات فاصله | ۳۲۷۶۱۶۰۰۰۰۰ | ۳۹۰۰۰۰       | ۱۶۳۸۴۰۰۰۰ |
| در حالت بهینه          |             | مجموع        | ۱۶۴۲۳۰۰۰۰ |



شکل ۸: نتایج ناحیه‌بندی تصویر خروجی شبکه SOM با ۶۴ رنگ



شکل ۹: تصویر کوهستان و خروجی شبکه SOM با ۶۴ نرون خروجی



شکل ۱۰: نتایج ناحیه‌بندی تصویر خروجی شبکه SOM با ۶۴ رنگ



شکل ۱۱: تصویر فیل و خروجی شبکه SOM با ۶۴ نرون خروجی

مقایسه نتایج روش پیشنهادی با روش مرجع [۳۰] در شکل (۲۱) آمده است. همان‌طور که مشاهده می‌شود، روش پیشنهادی تمایز بهتری بین اشیاء و محیط ایجاد کرده است، علت اصلی این است که در این دو تصویر مهم‌ترین ویژگی جهت تمایز، اطلاعات رنگی تصویر می‌باشد و با توجه اینکه عملکرد الگوریتم پیشنهادی بر اساس اطلاعات رنگی بوده و این دو تصویر نیز پراکندگی رنگی مناسبی دارند، الگوریتم پیشنهادی عملکرد بهتری داشته است. در صورتی که در روش سلسله مراتبی از اطلاعات لبه و شدت روشنایی استفاده می‌شود و با تبدیل تصویر رنگی به تصویر سطح خاکستری، بسیاری از اطلاعات مفید یا همان اطلاعات رنگی از بین می‌رود.



شکل ۲۱: مقایسه نتایج دو الگوریتم، سمت راست الگوریتم پیشنهادی  
سمت چپ الگوریتم نظارت‌نشده سلسله مراتبی [۳۰]


## ۶- نتیجه‌گیری و بحث

در این تحقیق جهت کاهش هزینه محاسباتی الگوریتم معرفی شده قبلی، سعی شد از یک شبکه عصبی SOM جهت خوشه‌یابی اولیه به‌منظور کاهش حجم داده‌های ورودی به الگوریتم استفاده شود. همان‌طور که جدول و تصاویر مشخص می‌کند حفظ نسبی نتایج و بهبود برای برخی تصاویر و به‌علاوه کاهش هزینه محاسباتی، از جمله مزایای این روش محسوب می‌شود. برای هر تصویر، شبکه عصبی SOM با تعداد نرون‌های مختلف در لایه خروجی به کار گرفته شد. همان‌طور که در جدول نتایج مشخص شده است، بهترین نتایج مربوط به شبکه عصبی SOM با ۶۴ و ۸۱ نرون خروجی می‌باشد. علت را این‌گونه می‌توان توضیح داد که برای شبکه SOM با ۴۹ نرون خروجی، نقاط دارای پراکندگی نسبی که عملاً در مرحله خوشه‌یابی نهایی باید در دو خوشه متفاوت قرار بگیرند، با توجه به محدود بودن تعداد خوشه‌ها در مرحله اول خوشه‌یابی، در یک خوشه قرار گرفته‌اند و بنابراین به دلیل میانگین‌گیری انجام‌شده، برخی از اطلاعات ریز مسئله از بین رفته است. برای شبکه SOM با ۱۰۰ نرون خروجی نیز با توجه به افزایش تعداد نرون‌های خروجی، آموزش انجام‌شده بر روی آن به نسبت سایر شبکه‌ها، اندکی ضعیف‌تر بوده است، از طرفی افزایش نرون‌ها، هزینه محاسباتی خوشه‌یابی اولیه را نیز افزایش می‌دهد. در مجموع با توجه به حجم بالای محاسبات الگوریتم هوش جمعی و همچنین محاسبه شاخص NDB که با افزایش تعداد داده ورودی،

۶۴ نرون خروجی استفاده شده و پارامترهای الگوریتم هوش جمعی نیز مانند تصاویر قبلی انتخاب شده است.

جدول ۲: نتایج شاخص برانزدگی NDB و تعداد K خوشه به‌دست‌آمده برای تصاویر مورد آزمایش به ازای الگوریتم‌های مختلف

| تصویر | شاخص | PABH- GSA |                |                |                |                 |
|-------|------|-----------|----------------|----------------|----------------|-----------------|
|       |      | بدون SOM  | SOM با ۴۹ نرون | SOM با ۶۴ نرون | SOM با ۸۱ نرون | SOM با ۱۰۰ نرون |
| کوه   | NDB  | ۰/۱۴۸۳    | ۰/۱۴۷۱         | ۰/۱۴۶۹         | ۰/۱۴۷۶         | ۰/۱۴۷۸          |
|       | K    | ۴         | ۴              | ۴              | ۴              | ۴               |
| مار   | NDB  | ۰/۲۷۷۶    | ۰/۲۸۱۰         | ۰/۲۸۴۱         | ۰/۲۸۴۶         | ۰/۲۹۲۵          |
|       | K    | ۳         | ۳              | ۳              | ۳              | ۳               |
| فیل   | NDB  | ۰/۲۵۱۷    | ۰/۲۵۸۶         | ۰/۲۴۳۰         | ۰/۲۴۵۶         | ۰/۲۷۰۸          |
|       | K    | ۴         | ۳              | ۴              | ۴              | ۳               |
| دست   | NDB  | ۰/۲۰۲۲    | ۰/۲۱۲۹         | ۰/۲۰۷۳         | ۰/۲۰۸۱         | ۰/۲۰۷۹          |
|       | K    | ۳         | ۳              | ۳              | ۳              | ۳               |
| اسب   | NDB  | ۰/۲۷۸۳    | ۰/۲۹۷۶         | ۰/۲۹۷۸         | ۰/۲۹۷۴         | ۰/۲۹۵۶          |
|       | K    | ۲         | ۲              | ۲              | ۲              | ۲               |



شکل ۱۷: تصویر ستاره دریایی و خروجی شبکه SOM با ۶۴ نرون خروجی



شکل ۱۸: نتایج ناحیه‌بندی تصویر خروجی شبکه SOM با ۶۴ رنگ



شکل ۱۹: تصویر کلیسا و خروجی شبکه SOM با ۶۴ نرون خروجی



شکل ۲۰: نتایج ناحیه‌بندی تصویر خروجی شبکه SOM با ۶۴ رنگ

- Algorithm,” *Pattern Recognition Letters*, vol. 29, no. 5, pp. 688–699, 2008.
- [16] Z. Yu and O.C. Au, “An Adaptive Unsupervised Approach toward Pixel Clustering and Color Image Segmentation,” *Pattern Recognition*, vol. 43, no. 5, pp. 1889–1906, 2009.
- [17] E. Rashedi and H. Nezamabadi-pour, “GSA: A Gravitational Search Algorithm,” *Information Sciences: an International Journal*, vol. 179, no. 13, pp. 2232–2248, 2009.
- [18] X.Yao and Y.Liu, “Evolutionary programming made faster,” *IEEE Transaction on Evolutionary Computation*, vol. 3, no. 2, pp. 82–102, 1999.
- [19] D.L. Davies and D.W. Bouldin, “A cluster separation measure,” *IEEE Trans. Pattern Anal. Machine Intell*, vol. PAMI-1, pp. 224–227, 1979.
- [20] J.C. Bezdek, “Cluster Validity with Fuzzy Sets,” *Cybernetics and systems*, vol. 3, no. 3, pp. 58–73, 1973.
- [21] X.L. Xie and G.A. Beni, “Validity Measure for Fuzzy Clustering,” *IEEE Trans. Pattern Anal. Mach. Intell*, vol. 13, no. 8, pp. 841–847, 1991.
- [22] C.H. Chou and M.C. Su, “A new cluster validity measure and its application to image compression,” *Pattern Anal*, vol. 7, no. 2, pp. 205–220, 2004.
- [23] <http://www.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/>
- [24] A.C. Bovik and M. Clark, “Multichannel Texture Analysis Using Localized Spatial Filters,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 1, pp. 55–73, 1990.
- [25] M. Tabb and N. Ahuja, “Multiscale image segmentation by integrated edge and region detection,” *IEEE Transactions on Image Processing*, vol. 6, no. 5, pp. 642–655, 1997.
- [26] S. Beucher and C. Lantuejoul, “Use of watersheds in contour detection,” *International workshop on image processing*, 1979.
- [27] T. Kohonen, “the Self-Organizing Maps,” *Proceeding of the IEEE*, vol. 78, no. 9, pp. 1464–1480, 1990.

[۲۸] علیرضا سردار و سیدحمید ظهیری، «استفاده از الگوریتم جستجوی گرانشی بهبودیافته در خوشه‌یابی خودکار تصاویر» فصل‌نامه علمی پژوهشی *رایانش نرم و فن‌آوری اطلاعات*، جلد ۱، شماره ۲، سال ۱۳۹۱.

[۲۹] معصومه محسنی، مهدی ازوجی و رضا قادری، «قطعه‌بندی تصویر مبتنی بر برش نرمالیزه گراف از دیدگاه میزان اطلاعات جداکننده»، *مجله مهندسی برق دانشگاه تبریز*، شماره ۱، صفحه ۳۰۳–۳۱۰، بهار ۱۳۹۵.

[۳۰] غلامرضا اکبری‌زاده، زینب تیرانداز و سیده مرجان آل سیدغفور، «بخش‌بندی نظارت‌نشده سلسله مراتبی تصاویر SAR با استفاده از سوپر پیکسل و فشرده‌سازی پر اتلاف داده»، *مجله مهندسی برق دانشگاه تبریز*، شماره ۲، صفحه ۱۴–۱، تابستان ۱۳۹۵.

بسیار زمان بر می‌شود، استفاده از پیش‌پردازش اولیه با یک شبکه عصبی SOM با تعداد ۶۴ نرون خروجی مناسب به نظر می‌رسد. همچنین برای کاربردهای خاصی که در آن تصاویری با تعداد رنگ کم و پراکندگی بسیار کمتر وجود دارد، این روش بسیار مناسب است و حتی می‌توان از شبکه‌های SOM با تعداد نرون کمتر استفاده کرد. مقایسه روش پیشنهادی با روش بخش‌بندی نظارت‌نشده سلسله مراتبی تصاویر نیز، عملکرد مناسب روش پیشنهادی را نشان می‌دهد.

## مراجع

- [1] M. Omran and A. Engelbrecht, “Particle swarm optimization method for image clustering,” *Int. J. Pattern Recognition Artificial Intell*, vol. 19, no. 3, pp. 297–321, 2005.
- [2] M. Omran and A. Salman, “Dynamic clustering using particle swarm optimization with application in unsupervised image classification,” *Computing and Technology*, vol. 9, no. 1, pp. 199–204, 2005.
- [3] K. Jain and R.C. Dubes, *Algorithms for Clustering Data*, Prentice-Hall, Englewood Cliffs, NJ, 1988.
- [4] R.O Duda and P.E hart, *Pattern classification and Scene Analysis*, John Willy & Sons, NY, USA, 1973.
- [5] J.T. Tou and R.C. Gonzalez, *Pattern Recognition Principles*, Addison-Wesley, Reading, 1974.
- [6] G. Ball and D. Hall, “A Clustering Technique for Summarizing Multivariate Data,” *Behavioral Science*, vol. 12, pp. 153–155, 1967.
- [7] D. Pelleg and A. Moore, “X-means: Extending K-means with efficient estimation of the number of clusters,” *Proceedings of the 17th International Conference on Machine Learning*, 2000.
- [8] S. Bandyopadhyay and U. Maulik, “Genetic clustering for automatic evolution of clusters and application to imageclassification,” *IEEE pattern recognition*, vol. 35, no. 6, pp. 1197–1208, 2002.
- [9] D.E. Goldberg, *Genetic Algorithms in Search, Optimization and machine learning*, Addison-Wesley, New York, 1989.
- [10] J.Kennedy and R.Eberhart, “Particle Swarm Optimization,” *Proceedings of IEEE International Conference on Neural Networks*, Perth, Australia, 1995.
- [11] M. Dorigo and V. Maniezzo, *The ant system: an autocatalytic optimizing process*, Technical Report, Politecnico di Milano, Italy, 1991.
- [12] C.F. Tsai and C.W. Tsai, “ACODF: a novel data clustering approach for data mining in large databases,” *The Journal of Systems and Software*, vol. 73, no. 1, pp. 133–145, 2004.
- [13] U. Maulick and S. Bandyopadhyay, “genetic Algorithm based Data Clustering Techniques,” *pattern recognition*, vol. 33, pp. 1455–1465, 2000.
- [14] V. Katari and S.C. Satapathy, “Hybridized Improved Genetic Algorithm with Variable Length Chromosome for Image Clustering,” *IJCSNS International Journal of Computer Science and Network Security*, vol. 7, no. 11, pp. 121–131, 2007.
- [15] D. Swagatam and A. Ajit, “Automatic kernel clustering with a Multi-Elitist Particle Swarm Optimization

## زیرنویس‌ها

- <sup>1</sup> Supervised clustering
- <sup>2</sup> Unsupervised clustering
- <sup>3</sup> Particle Swarm Optimization
- <sup>4</sup> Genetic Algorithm
- <sup>5</sup> Ant Colony Optimization
- <sup>6</sup> Genetic clustering for unknown K
- <sup>7</sup> Variable Length Improved Genetic Algorithm
- <sup>8</sup> Dynamic Clustering using Particle Swarm Optimization
- <sup>9</sup> Multi-Elitist Particle Swarm Optimization
- <sup>10</sup> Improved Ant colony-Fuzzy c-means Hybrid Algorithm
- <sup>11</sup> Gravitational Search Algorithm
- <sup>12</sup> Planets and Black Holes GSA
- <sup>13</sup> Self-Organizing Maps
- <sup>14</sup> Davies-Bouldin
- <sup>15</sup> New DB