

خوشه‌بندی خودکار با استفاده از الگوریتم‌های تکاملی و فرا ابتکاری در بازیابی مبتنی بر محتوای تصاویر موجودات دریایی

زبیر رئیسی^{۱*}، جواد آذرخش^۲

۲، ۱- دانشگاه دریانوردی و علوم دریایی چابهار، دانشکده مهندسی دریا

کد مقاله: ۹۵۰۱

تاریخ پذیرش نهایی: ۱۳۹۵/۰۳/۱۰

تاریخ دریافت مقاله: ۱۳۹۵/۰۱/۱۶

چکیده

در سال‌های اخیر گسترش شبکه‌های اینترنتی و ابزارهای موبایل با قابلیت‌های تصویر برداری و اتصال به شبکه موجب تعریف خدمات و کاربردهای جدید با استفاده از این ابزارها شده‌است. هدف این مقاله ایجاد سرویس‌های جدیدی برای صنعت موجودات دریایی با استفاده از این مجموعه امکانات و همچنین با استفاده از تکنیک‌های بازیابی مبتنی بر محتوای تصاویر دیجیتال می‌باشد. در این مقاله از روش خوشه‌بندی خودکار با استفاده از الگوریتم‌های تکاملی و فرا ابتکاری به منظور شناسایی و طبقه‌بندی انواع تصاویر موجودات دریایی استفاده شده‌است. برای این منظور پایگاه داده‌ای از تصاویر موجودات دریایی ایجاد شد و روش خوشه‌بندی *k-means* با استفاده از الگوریتم‌های تکاملی و بهینه‌سازی بر روی تصاویر اعمال گردید. نتایج بازیابی نشان داد که خوشه‌بندی خودکار با استفاده از الگوریتم بهینه‌سازی ذرات (*PSO*) دارای میانگین دقت بازیابی بالاتری نسبت به سایر روش‌هاست.

کلیدواژه: بازیابی تصویر، تصاویر موجودات دریایی، استخراج ویژگی، خوشه‌بندی خودکار، الگوریتم‌های تکاملی و فرا ابتکاری

* Corresponding author

E-mail address: zobeir.raisi@cmu.ac.ir

Postal Address: Faculty of Marine Engineering, Chabahar Maritime University, Chabahar, IRAN

مقدمه

در دهه‌ی اخیر به دلیل گسترش روز افزون اینترنت و در دسترس بودن ابزار تصویربرداری مانند دوربین‌های دیجیتال و اسکنرهای تصویر، روزانه حجم زیادی از تصویر تولید می‌شود. [۱]–[۳]. تصاویر دیجیتال شامل تصاویری از بافت‌ها، تصاویر طبیعی، تصاویر حیوانات و گیاهان، امضاها، دیجیتالی، تصاویر اثر انگشت، تصاویر چهره، نقشه‌های دیجیتالی، تصاویر پزشکی، تصاویر هنری و ... می‌باشد. به هر حال این تصاویر روز به روز در حال گسترش‌اند. در نتیجه چگونگی یافتن تصویر مورد نظر از این پایگاه‌های داده در حال گسترش، به یکی از سوال‌های بسیار مهم تحقیقاتی تبدیل شده‌است.

برای این منظور الگوریتم‌های سنتی بازیابی تصویر که بر اساس متن ارائه شده‌اند نمی‌توانند خواسته کاربر را برآورده سازند [۴]. بنابراین این روزها فناوری بازیابی تصاویر بر اساس محتوا (CBIR) بیشتر مورد توجه مردم قرار گرفته‌اند [۵]. در یک فرآیند CBIR، ابتدا ویژگی‌های کل تصاویر موجود در پایگاه داده استخراج شده و به طور موثر ذخیره می‌شوند، سپس برای یک تصویر نمونه (مورد جست‌وجو) بعد از استخراج ویژگی‌های آن با استفاده از یک معیار، ویژگی‌های استخراج شده با ویژگی‌های ذخیره شده کل تصاویر مقایسه می‌شوند و پس از مرتب‌سازی فاصله‌های تشابهی، نتایج بازیابی به کاربر بازگردانده می‌شود. در شکل ۱ فرآیند سیستم CBIR مورد مطالعه در این مقاله نشان داده شده‌است.

در CBIR، تصاویر با استفاده از محتویات بینایی خودشان مانند رنگ [۱۱]، بافت [۱۲] و شکل نمایه‌گذاری می‌شوند [۷].

یکی از روش‌های رایج در سیستم‌های بازیابی تصویر، هیستوگرام رنگ‌است، زیرا هیستوگرام رنگ بسیار ساده و سریع محاسبه می‌شود؛ علاوه بر این هیستوگرام رنگ در مقابل نویز و چرخش تصاویر مقاوم‌است. بافت یکی از ویژگی‌های بصری و درونی تصویر است که به رنگ و روشنایی تصویر وابسته نیست. این ویژگی همگنی تصویر را منعکس می‌کند. بافت حاوی اطلاعات سطح تصویر و همچنین اطلاعات محیط اطراف تصویر می‌باشد. اطلاعات مکانی تصویر به صورت کمی با استفاده از ویژگی بافت بیان می‌شود.

شکل یکی از ویژگی‌های اساسی برای نشان دادن اشیاء در تصویر می‌باشد، به طوری که با استفاده از این ویژگی می‌توان دقت و بازده سیستم CBIR را بهبود بخشید. به طور کلی دو روش برای نمایش ویژگی‌های شکل وجود دارد: یکی مبتنی بر کانتور و دیگری مبتنی بر ناحیه [۹]، [۱۰]. روش‌هایی که برای استخراج ویژگی‌های این دو نوع نمایش شکل به کار می‌رود به ترتیب عبارتند از: توصیف-گر فوریه و لحظات ثابت.

با وجود این که الگوریتم‌های پیچیده‌ی بسیاری برای توصیف رنگ، بافت و شکل طراحی شده‌است، اما این الگوریتم‌ها نمی‌توانند مدل خوبی از معناشناسی تصویر ارائه دهند و هنگام برخورد با پایگاه‌های داده‌ی تصویری بزرگ بازیابی خوبی را نشان نمی‌دهند. آزمایش‌های گسترده روی سیستم‌های CBIR نشان می‌دهد که محتویات سطح پایین (مانند رنگ، بافت و شکل) اغلب قادر به توصیف مفاهیم سطح بالای معنایی که توسط کاربر از یک تصویر درک می‌شود، نیستند [۱۶، ۱۷]. بنابراین عملکرد CBIR هنوز دور از انتظارات کاربران می‌باشد.

خوشه‌بندی یکی از مسائلی است که در حوزه یادگیری و بینایی ماشین مطرح می‌شود و در حوزه‌های مختلف کاربرد دارد. برای حل این مساله روش‌های مختلفی وجود دارد. الگوریتم‌های کلاسیکی که برای حل مسایل خوشه‌بندی استفاده می‌شوند گاهی اوقات کارایی لازم برای حل این مساله را ندارند. به همین دلیل می‌توان از الگوریتم‌های فرا ابتکاری یا بهینه‌سازی هوشمند برای حل این مساله استفاده کرد. برای تبدیل مساله خوشه‌بندی به مساله بهینه‌سازی، نیازمند شاخص‌هایی هستیم که به این منظور، در این مقاله، از دو شاخص معروف در حوزه داده کاوی تکاملی، استفاده شده‌است.

الگوریتم ژنتیک (Genetic Algorithm) یا به اختصار GA، به طور قطع شناخته شده ترین روش بهینه‌سازی هوشمند و الگوریتم تکاملی است، که کاربردهای فراوانی در رشته‌های مختلف علمی و مهندسی دارد. اهمیت این الگوریتم در محاسبات تکاملی و هوش محاسباتی به قدری است که اولین کلمه‌ای که پس از عبارت "الگوریتم تکاملی" به ذهن می‌رسد، الگوریتم ژنتیک است. بسیاری از افراد، سایر روش‌های بهینه‌سازی هوشمند را، نسخه‌های تغییر یافته‌ای از الگوریتم ژنتیک می‌شناسند و قائل به اصالت وجود و ماهوی سایر الگوریتم‌ها نیستند. این ابزار محاسباتی، در اوایل دهه ۱۹۷۰ از دل نتایج پدید آمد، که از تلاش‌های مهندسان و دانشمندان آن روزگار برای شبیه‌سازی فرایند تکامل، صورت پذیرفته بود. مبتکر ایده الگوریتم‌های ژنتیک، جان هالند بود و پس از وی، یکی از شاگردانش به نام دیوید گولدبرگ، تلاش فراوانی برای توسعه الگوریتم‌های ژنتیک انجام داده‌است [۱۹].

الگوریتم بهینه‌سازی ازدحام ذرات یا Particle Swarm Optimizatoion به اختصار (PSO) یکی از مهم ترین الگوریتم‌های بهینه‌سازی هوشمند است که در حوزه هوش ازدحامی (Swarm Intelligence) جای می‌گیرد. این الگوریتم، توسط جیمز کندی و راسل سی ابرهارت در سال ۱۹۹۵ معرفی گردید، و با الهام از رفتار اجتماعی حیواناتی چون ماهی‌ها و پرندگان که در گروه‌هایی کوچک و بزرگ کنار هم زندگی می‌کنند، طراحی شده‌است. در الگوریتم PSO، اعضای جمعیت جواب‌ها، به صورت مستقیم با هم ارتباط دارند و از طریق تبادل اطلاعات با یکدیگر و یادآوری خاطرات خوب گذشته، به حل مساله می‌پردازند [۲۰].

الگوریتم تکامل تفاضلی (Differential Evolution) و یا به اختصار DE، یک الگوریتم بهینه‌سازی هوشمند و مبتنی بر جمعیت است که در سال ۱۹۹۵ توسط Storn و Price معرفی گردید. نسخه ابتدایی این الگوریتم برای حل مسائل پیوسته ارائه شده بود، اما به مرور زمان نسخه‌هایی از این الگوریتم ارائه شدند که برای حل مسائل بهینه‌سازی گسسته طراحی شده‌اند [۲۱-۲۳].

زنبورهای عسل از جمله حشراتی هستند که در کلونی‌ها و مجموعه‌های نسبتاً بزرگ در کنار یکدیگر زندگی می‌کنند و علاوه بر منافع که در زمینه کشاورزی، باغداری و تولید عسل و موم از این حشره مفید کسب می‌شود، رفتار اجتماعی منظم این موجودات، همواره منشأ الهام و مبدأ مطالعات علمی قرار گرفته‌است. تا کنون نسخه‌های مختلفی از الگوریتم‌های بهینه‌سازی ارائه شده‌اند، که از رفتار گروهی زنبورها برگرفته شده‌اند. الگوریتم کلونی زنبور مصنوعی یا Artificial Bee Colony به اختصار ABC یکی از نسخه‌های معروف از دسته الگوریتم‌های مبتنی بر زنبورهای عسل شناخته می‌شود [۲۵].

در این مقاله تمرکز اصلی بر روی اعمال الگوریتم خوشه‌بندی بر روی تصاویر موجودات دریایی و پیدا کردن یک سیستم بازیابی مبتنی بر محتوای دقیق و کارآمد بر روی این تصاویر می‌باشد. در ادامه، ما یک سیستم بازیابی مبتنی بر محتوای تصویر را برای انواع تصاویر موجودات دریایی اعمال کردیم، که برای این منظور ویژگی‌های شکل، رنگ و بافت تصاویر را استخراج کرده و یک روش پیشنهادی که به صورت خودکار با استفاده از الگوریتم‌های تکاملی و فرا ابتکاری بهترین خوشه‌ها را از تصویر استخراج می‌کند، ارائه کردیم که این روش پیشنهادی باعث افزایش دقت بازیابی تصویر می‌گردد. ما امیدواریم که این سیستم به محققین این صنعت در طبقه‌بندی و شناسایی تصاویر جانداران دریایی کمک کند.

خوشه‌بندی

خوشه‌بندی یک مساله یادگیری غیر نظارتی است، در این مساله در حالت کلی یک مجموعه شی را طوری طبقه‌بندی می‌کنیم که هیچ کس هیچگونه اطلاعاتی را به ما نداده باشد. خوشه‌بندی دو ویژگی و هدف بسیار مهم دارد:

(الف) پیوستگی: یعنی این که اعضای موجود در گروه‌های تشکیل شده، باید بیشترین شباهت را به یکدیگر داشته باشند یا به عبارت دیگر آن گروه بیشترین پیوستگی را داشته باشد.

(ب) تفکیک: در این حالت، گروه‌ها را باید طوری تعریف کنیم که اعضای این گروه‌ها کمترین شباهت را داشته باشند.

پس در حالت کلی بین اعضای یک گروه باید بیشترین شباهت وجود داشته باشد و بین اعضای دو گروه کمترین تفکیک پذیری باشد و یا کمترین شباهت بین آنها وجود داشته باشد. این عبارتهای کمترین و بیشترین این سوال را در ذهن پیش می‌آورد که مساله خوشه‌بندی یک مساله بهینه‌سازی باشد. پس می‌توان از الگوریتم‌های تکاملی و فرا ابتکاری مختلف برای حل این گونه مسایل استفاده کرد.

مساله K-means:

یکی از مهمترین مسایلی که در مبحث خوشه‌بندی مطرح می‌شود مساله‌ی k-means است [۲۶]. در حالت کلی مساله k-means به صورت زیر بیان می‌شود:

فرض کنید مجموعه داده‌های X را به صورت زیر داریم:

$$X = \{x_1, x_2, \dots, x_n\}, x_i \in \mathbb{R}^D \quad (1)$$

و مراکز خوشه‌ها هم به صورت زیر باشند:

$$M = \{m_1, m_2, \dots, m_n\}, m_j \in \mathbb{R}^D \quad (2)$$

اگر x_i ها در فضای d بعدی باشند، m_i ها هم در فضای d بعدی خواهند بود. پس تعداد کل مجهولات $k \times d$ خواهد بود.

تابع هدف:

مجموع به ازای همه کلاسترها ($j = 1, 2, \dots, k$)، مجموع فاصله همه اعضای این کلاستر را تا مرکز به دست می‌آوریم، بنابراین تابع هدف به صورت زیر تعریف می‌شود.

$$Obj.Fun = \sum_{i=1}^k \sum_{x \in c_j} d(x_i, m_j) \quad (3)$$

در رابطه‌ی فوق وقتی x عضو کلاستر m_j باشد، کمترین فاصله را با مرکز آن کلاستر دارد؛ پس به ازای همه‌ی داده‌ها می‌نیمیم فاصله‌ی بین این x و m_j ها به صورت زیر به دست می‌آید:

$$Obj.Fun = \sum_{i=1}^n \min_{1 \leq j \leq k} d(x_i, m_j) \quad (4)$$

پس به صورت کلی یک مجموعه داده داریم که n تا بردار d بعدی هستند، می‌خواهیم k تا نقطه‌ی d بعدی در همان فضا به عنوان مرکز کلاستر پیدا کنیم به نحوی که تابع هدف کمینه باشد (x و k هم معلوم هستند).

الگوریتم هیروستیک Lloyd


یکی از الگوریتم‌هایی که به صورت استاندارد برای حل مسأله k-means به کار می‌رود الگوریتم Lloyd است. این الگوریتم شامل دو فاز رقابت و به روز رسانی می‌باشد.

فاز رقابت:

در این فاز هر عضو از مجموعه‌ی داده به نزدیکترین مرکز کلاستر اختصاص داده می‌شود یا به عبارت دیگر هر مرکز کلاستر با بقیه مراکز به رقابت می‌پردازد و نقطه‌ای که به آن نزدیکتر است را می‌گیرد.

فاز به روز رسانی:


بعد از فاز رقابت، اعضای که در یک کلاستر قرار می‌گیرند، گویا انتخاباتی را برگزار می‌کنند و آن مرکز را با میانگین خودشان جایگزین می‌کنند. شکل ۱ طرز کار این الگوریتم را شرح می‌دهد.



شکل ۱- نمایش الگوریتم Lloyd برای حل مسأله k-means

خوشه‌بندی خودکار

یکی از انواع پیچیده مسائل خوشه‌بندی، زمانی طرح می‌شود که تعداد خوشه‌ها نیز نامعلوم باشد و الگوریتم خوشه‌بندی موظف به پیدا کردن تعداد خوشه‌ها باشد. این مسأله، اصطلاحاً با نام خوشه‌بندی خودکار یا Automatic Clustering شناخته می‌شود؛ آن چنان که خود مسأله خوشه‌بندی را، معمولاً با نام Classification Automatic نیز می‌شناسیم. اگر در مسأله k-means تعداد مجهولات معلوم نباشد، این مسأله به مسأله خوشه‌بندی خودکار تبدیل می‌شود. در حالت کلی طبق شکل ۲ خوشه‌بندی خودکار شامل دو بخش است. یک بخش فعال ساز و یک بخش مختصات مراکز.



شکل ۲- نمایش کد شده‌ی بخش‌های مختلف خوشه‌بندی خودکار

حل مسأله خوشه‌بندی در حالت کلی و مسأله خوشه‌بندی خودکار به صورت خاص، بعضاً می‌تواند خارج از توان الگوریتم‌های رایج خوشه‌بندی باشد. یکی از راه‌حلهایی که برای این موضوع در نظر گرفته شده‌است، تبدیل مسأله خوشه‌بندی به یک مسأله بهینه‌سازی و حل آن با استفاده از الگوریتم‌های بهینه‌سازی هوشمند و تکاملی است [۲۶]، که موضوع بحث ما در این مقاله نیز می‌باشد. در این مقاله، از پنج الگوریتم بهینه‌سازی هوشمند شامل الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات، تکامل تفاضلی و کلونی زنبورهای مصنوعی برای حل مسأله خوشه‌بندی خودکار استفاده شده‌است. برای این منظور در این مقاله از شاخص‌هایی که در ادامه آمده‌است استفاده می‌نماییم.

شاخص اعتبار:

مسأله‌ی خوشه‌بندی که در قسمت قبل مطرح شد، حالت تفکیک پذیری را به خوبی در نظر نگرفته‌است؛ خصوصاً زمانی که تعداد خوشه‌ها دچار تغییرات زیاد شوند، مسأله k -means جواب قابل قبولی ارائه نمی‌دهد. معیار یا شاخص اعتبار باعث می‌شود دو عامل مهم خوشه‌بندی (پیوستگی و تفکیک پذیری) در نظر گرفته شوند.

شاخص‌های زیادی مانند [۲۷] Dunn's index (DI)، [۲۸] Calinski-Harabasz index، [۲۹] Pakhira Bandyopadhyay Maulik (PBM) index، [۳۰] و [۳۱] CS measure وجود دارند. در این مقاله از دو شاخص DB و CS برای خوشه‌بندی خودکار انتخاب شده‌اند که این شاخص‌ها نسبت به بقیه جواب بهتری را ارائه می‌دهند [۲۶].

شاخص DB

شاخص DB یانددیس (Davies and Bouldin) در سال ۱۹۷۹ معرفی شده است [۲۸] و برای ارزیابی اعتبار خوشه‌بندی خودکار مورد استفاده قرار می‌گیرد. در حالت کلی این شاخص به صورت زیر تعریف می‌شود:

$$DB = \frac{\text{فاصله درون کلاسترها}}{\text{فاصله بین کلاسترها}} \quad (۵)$$

با توجه به رابطه فوق ما به دنبال این هستیم که فاصله درون کلاسترها کم و فاصله بین کلاسترها زیاد شود که این باعث می‌شود DB کم شود. از طرفی چون فاصله و شباهت باهم رابطه عکس دارند کاهش DB باعث افزایش شباهت می‌گردد.

پراکندگی اعضای یک خوشه هم به صورت زیر تعریف می‌شود:

$$S_{i,q} = \sqrt[q]{\frac{1}{N_i} \sum_{x \in c_i} d(x, m_i)^q} \quad (۶)$$

که N_i تعداد اعضای خوشه i است و $d(x, m_i)$ به صورت زیر تعریف می‌شود:

$$d(x, m_i) = \|x - m_i\|_2 \quad (۷)$$

هرچه مقدار $S_{i,q}$ بزرگتر باشد، خوشه i فضای بیشتری را شامل می‌شود. فاصله مرکز دو خوشه به صورت زیر تعریف می‌شود:

$$d_{i,j,t} = \sqrt[t]{\sum_{p=1}^d |m_{i,p} - m_{j,p}|^t} = \|m_i - m_j\|_t \quad (۸)$$

و فاصله درون خوشه‌ها هم به صورت زیر تعریف می‌شود:

$$R_{i,q,t} = \max_j \frac{S_{i,q} + S_{j,q}}{d_{i,j,t}}, j \neq i \quad (۹)$$

پارامتر فوق نشان دهنده این است که خوشه i بیشترین تفکیک را دارد. با توجه به روابط تعریف شده در بالا می‌توان DB را به صورت زیر تعریف کرد:

$$DB = \frac{1}{k} \sum_{i=1}^k R_{i,q,t} \quad (۱۰)$$

شاخص CS

شاخص CS یا اندیس (Chou, Su and Lai) در سال ۲۰۰۴ معرفی شده است و برای ارزیابی اعتبار خوشه‌بندی خودکار مورد استفاده قرار می‌گیرد [۲۷]. در حالت کلی شرح این شاخص به صورت زیر است:

فرض کنید یک مجموعه داده مانند X_p داریم که متعلق به خوشه i باشند ($x_p \in C_i$)، بیشترین فاصله‌ایی که اعضای آن خوشه از این داده دارند به صورت زیر تعریف می‌شود:

$$d_p^{\max} = \max_{x_q \in C_i} d(x_p, x_q) \quad (11)$$

میانگین بیشترین فاصله‌ی اعضا از بقیه اعضای آن خوشه به صورت زیر تعریف می‌شود:

$$\bar{d}_i = \frac{1}{N_i} \sum_{x_p \in C_i} d_p^{\max} = \frac{1}{N_i} \sum_{x_p \in C_i} \max_{x_q \in C_i} d(x_p, x_q) \quad (12)$$

که نشان دهنده وسعت خوشه است که هرچه این پارامتر بزرگتر باشد نشان دهنده این است که اعضا بیشتر از هم فاصله دارند. بنابراین بر اساس این پارامترها شاخص CS به صورت زیر تعریف می‌شود:

$$CS = \frac{\sum_i \frac{1}{N_i} \sum_{x_p \in C_i} \max_{x_q \in C_i} d(x_p, x_q)}{\sum_i \min_{j \neq i} d(m_i, m_j)} \quad (13)$$

ما در این شاخص دنبال این هستیم که CS را کم کنیم پس باید صورت کم و مخرج زیاد باشد.

الگوریتم‌های اصلی بازیابی تصویر

در این مقاله از الگوریتم‌های اصلی بازیابی تصویر که در ادامه به طور خلاصه در مورد آنها توضیح داده می‌شود برای بازیابی تصویر استفاده شده است.

استخراج ویژگی رنگ

رنگ یکی از ویژگی‌های ذاتی و آشکار تصویر است. این ویژگی در برابر تغییرات اندازه، جهت، نویز و شفافیت تصویر مقاوم است [۸]. الگوریتمی که در این مقاله برای استخراج ویژگی رنگ استفاده شده است، لحظات رنگ^۲ است. لحظات رنگ در فضاهای رنگی مختلف استخراج می‌شوند اما فضای رنگ RGB نسبت به سایر فضاها از عملکرد بهتری برخوردار است.

یکی از مزایای استخراج ویژگی با استفاده از لحظات رنگ، سادگی و توانایی نمایش تمام توزیع‌های رنگ موجود در تصویر است. در این مقاله از هیس‌توگرام رنگ به عنوان ویژگی استخراج شده رنگ تصویر استفاده شده است. این روش در مقاله به صورت کامل آورده شده است [۲۴، ۳۲].

استخراج ویژگی شکل

شکل یکی از ویژگی‌های اساسی برای نشان دادن اشیا در تصویر می‌باشد، به طوری که با استفاده از این ویژگی می‌توان دقت و بازده سیستم CBIR را بهبود بخشید. به طور کلی دو روش برای نمایش ویژگی‌های شکل وجود دارد: یکی مبتنی بر کانتور و دیگری مبتنی بر ناحیه [۹][۱۰]. روش‌هایی که برای استخراج ویژگی‌های این دو نوع نمایش شکل به کار می‌رود به ترتیب عبارتند از: توصیف‌گر فوریه و لحظات ثابت [۹]. در این مقاله برای استخراج ویژگی شکل، روش لحظات زرنیک، به دلیل مقاوم بودن آن در برابر چرخش تصویر و سادگی محاسبات استفاده شده است [۹][۱۰]. این روش در مقاله‌های به صورت کامل آورده شده است [۲۴، ۳۲].

استخراج ویژگی بافت

بافت یکی از ویژگی‌های بصری و درونی تصویر است که به رنگ و روشنایی تصویر وابسته نیست [12]. این ویژگی همگنی تصویر را منعکس می‌کند. ویژگی بافت حاوی اطلاعات سطح تصویر و همچنین اطلاعات محیط اطراف تصویر می‌باشد. اطلاعات مکانی تصویر به صورت کمی با استفاده از ویژگی بافت بیان می‌شود. Harlick و همکارانش برای آنالیز بافت تصویر، ماتریس Co-Occurrence سطح خاکستری (GLCM^۳) را به صورت زیر برای استخراج ویژگی تعریف کرده‌اند که ۱۴ ویژگی دارد [۱۳]. در این مقاله از همین روش که بردار ویژگی آن شامل ۸ مولفه می‌باشد به عنوان ویژگی بافت استفاده شده است [۲۴].

نتایج تجربی:










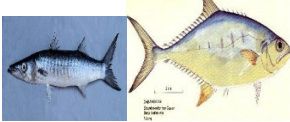

پایگاه داده:

پایگاه داده تصویر استفاده شده در این مطالعه شامل تصاویری از موجودات دریایی است که این تصاویر از اداره کل شیلات سیستان و بلوچستان و موتور جست‌وجوگر تصاویر گوگل دریافت شده‌اند. کل پایگاه داده شامل ۳۰۰ تصویر می‌باشد که از ۱۰ نوع گونه دریایی آماده شده‌اند. گونه‌هایی که در این مطالعه استفاده

^۳ Gray low-level Co-occurrence Matrix

شده‌اند موجودات دریایی هستند که در دریای عمان و خلیج چابهار وجود دارند^۴. جدول ۱ نمونه‌ای از هر یک از گونه‌های دریایی مورد استفاده در این مطالعه را نشان می‌دهد.

جدول ۱- یک نمونه از تصاویر موجودات دریایی تمام گونه‌های مورد مطالعه

تصویر	نام گونه	تصویر	نام گونه
	۶ لاک پشت		۱ عروس دریایی
	۷ جلبک		۲ مرجان دریایی
	۸ کرم دریایی		۳ سفره ماهی
	۹ اسب دریایی		۴ ستاره دریایی
			۵ صدف
			۱۰ ماهی‌های خلیج فارس

^۴ تمامی این تصاویر به همراه سورس برنامه برای استفاده محققین در این زمینه در لینک <http://zraisi.eostad.org> قرار داده شده‌اند.

معیار ارزیابی

در این مطالعه، برای ارزیابی عملکرد هر کدام از روش‌های بازیابی از معیار دقت^۵ و فراخوانی^۶ استفاده شده است که برای اولین بار توسط (Mehtre, Kankanhalli, and Lee (1997)) پیشنهاد گردید [۱۶]. این معیار در اغلب مقالات به عنوان معیار ارزیابی عملکرد سیستم CBIR استفاده شده است [۱۷][۱۸][۱۹]. دقت و فراخوانی k امین تصویر مورد جست‌وجو به صورت زیر تعریف می‌شوند:

$$precision(k) = \frac{n_k}{L} \quad \text{and} \quad recall(k) = \frac{n_k}{N_d} \quad (14)$$

در رابطه فوق، L تعداد تصاویر بازیابی شده است. n_k ، تعداد تصاویر مرتبط با تصویر مورد جست‌وجو در L تصویر بازیابی شده است. N_d ، تعداد کل تصاویر مرتبط با تصویر مورد جست‌وجو در پایگاه داده تصاویر است.

نتایج :

پارامترهای مورداستفاده مربوط به الگوریتم‌های مختلف در این مقاله براساس جداول زیر می‌باشد.

جدول ۲- پارامترهای مربوط با الگوریتم ژنتیک

Maximum Iteration	Population	Mutation Rate	Crossover percentage	Selection pressure	Mutation percentage	پارامتر
200	100	0.02	0.8	8	0.3	مقدار

این روش معمولاً به تعداد تکرار زیادی نیاز دارد و جواب خوبی هم در شاخص CS ارائه نمی‌کند.

جدول ۳- پارامترهای مربوط با PSO

Maximum Iteration	Population	Construction coefficient	پارامتر
-------------------	------------	--------------------------	---------

مقدار	$\varphi_1 = \varphi_2 = 2.05$	100	200
-------	--------------------------------	-----	-----

این روش در مقایسه با روش‌های دیگر خیلی سریع‌است و جواب قابل قبولی هم در هر دو شاخص ارائه می‌کند.

جدول ۴- پارامترهای مربوط با الگوریتم abc

پارامتر	Acceleration coefficient upper band	Population number of bees	Maximum Iteration
مقدار	1	100	200


جدول ۵- پارامترهای مربوط با الگوریتم DE

پارامتر	Cross over probability	upper band of scaling factor	Lower band of scaling factor	Population	Maximum Iteration
مقدار	0.2	0.8	0.5	50	200

شاخص DB برای داده‌های این مقاله شاخص بهتری هست .


ارزیابی عملکرد هر کدام از روش‌های فوق

برای ارزیابی عملکرد هر کدام از روش‌های فوق، ما به عنوان طراح مساله یک مجموعه داده با مراکز زیر تولید کردیم $m\{1\} = [0,0]$ ، $m\{2\} = [3,4]$ و $m\{3\} = [6,1]$ و اطراف هر مرکز به صورت تصادفی و با توزیع نرمال گوسی تعدادی داده پخش کردیم، تا بتوانیم عملکرد هر یک از روش‌ها را بهتر ارزیابی کنیم. تعداد داده‌ها در اطراف هر مرکز ۳۰۰ تا است. مجموعه داده تولیدی در شکل ۳ آورده شده‌است.




شکل ۳- مجموعه داده تولیدی برای ارزیابی الگوریتم‌های مختلف


نتایج حاصل از اعمال هر کدام از الگوریتم‌ها بر مجموعه داده فوق به منظور خوشه‌بندی خودکار با دو شاخص معرفی شده در زیر آمده است.




۴-۱- الف) اعمال الگوریتم ژنتیک بر مجموعه داده تولیدی با استفاده از شاخص DB




۴-۱- ب) اعمال الگوریتم ژنتیک بر مجموعه داده تولیدی با استفاده از شاخص CS




۴-۲- الف) اعمال الگوریتم PSO بر مجموعه داده تولیدی با استفاده از شاخص DB




۴-۲- ب) اعمال الگوریتم PSO بر مجموعه داده تولیدی با استفاده از شاخص CS




۴-۳- الف) اعمال الگوریتم abc بر مجموعه داده تولیدی با استفاده از شاخص DB



۴-۳- ب) اعمال الگوریتم abc بر مجموعه داده تولیدی با استفاده از شاخص CS



۴-۴-الف) اعمال الگوریتم DE بر مجموعه داده تولیدی با استفاده از شاخص DB




۴-۴-ب) اعمال الگوریتم DE بر مجموعه داده تولیدی با استفاده از شاخص CS

شکل ۴- اعمال الگوریتم‌های تکاملی و فرا ابتکاری مختلف بر مجموعه داده تولیدی

در این کار ما تمامی الگوریتم‌های بهینه‌سازی را در ابتدا برای تعداد ۱۰ خوشه تنظیم کردیم ولی خود الگوریتم‌ها با توجه به معیارهای DB و CS سه یا بعضاً چهار خوشه را پیدا کردند. همان‌طور که از شکل‌های فوق پیداست شاخص DB در مقایسه با شاخص CS نتایج بهتری ارائه داده است. در تمامی الگوریتم‌ها شاخص DB به صورت خودکار تعداد ۳ خوشه را پیدا کرده است در حالی که شاخص CS در بعضی موارد نه تنها ۳ خوشه را پیدا کرده، بلکه مراکز خوشه‌ها را نیز به درستی پیدا نکرده است. از این قسمت می‌توان نتیجه گرفت که شاخص DB برای مجموعه داده مورد استفاده در این مقاله بهتر است.

اعمال خوشه‌بندی خودکار به منظور بازیابی تصویر

برای این منظور ابتدا با استفاده از الگوریتم‌های معرفی شده در قسمت بالا، خوشه‌بندی خودکار با استفاده از شاخص DB که دارای نتیجه خوشه‌بندی بهتری نسبت به شاخص CS است، بر روی تمام تصاویر مجموعه داده اعمال شد. در زیر یک نمونه تصویر که الگوریتم‌های فوق بر آن اعمال شده‌اند دیده می‌شود. بهترین نتیجه بازیابی تصویر، خوشه‌بندی خودکار با استفاده از الگوریتم PSO به دست آمده است.



الف

ب

ج



ه

د

شکل ۵- الف) تصویر اصلی. ب) خوشه‌بندی شده با استفاده از ABC با $(k=7)$ خوشه. ج) خوشه‌بندی شده با استفاده از DE با $(k=7)$ خوشه د) خوشه‌بندی شده با استفاده از GA با $(k=4)$ خوشه ه) خوشه‌بندی شده با استفاده از PSO با $(k=8)$ خوشه

نتایج حاصل از این ارزیابی روی تصاویر مورد جست‌وجو برای ویژگی هیستوگرام رنگ HSV، بافت و شکل در جدول ۲ آورده شده‌اند. همان‌طور که از جدول پیداست نتایج حاصل از بازیابی با توجه به میانگین دقت به دست آمده از هر سه روش اصلی بازیابی تقریباً یکسان است. پس می‌توان از هر یک از آن‌ها به عنوان نماینده الگوریتم بازیابی به منظور استخراج ویژگی‌ها در تصاویر خوشه‌بندی شده استفاده کرد.

جدول ۶- نتایج دقت بازیابی براساس الگوریتم‌های اصلی

شکل (Zernike)	بافت (GLCM)	رنگ (Hsv Hist)	تصویر مورد جست‌وجو
0.415	0.798	0.754	عروس دریایی
0.598	0.415	0.598	مرجان دریایی
0.671	0.863	0.479	سفره ماهی
0.527	0.706	0.523	ستاره دریایی
0.827	0.443	0.980	اسفنج
0.598	0.370	0.754	لاک پشت
0.598	0.751	0.981	جلیک
0.863	0.598	0.598	کرم دریایی

0.618	0.598	0.598	اسب دریایی
0.980	0.751	0.618	ماهی‌های خلیج فارس
0.669	0.629	0.688	میانگین دقت

جدول ۷- نتایج حاصل از بازیابی با استفاده از خوشه‌بندی الگوریتم‌های فرا ابتکاری

PSO	GA	DE	ABC	الگوریتم‌های فرا ابتکاری
<u>0.956</u>	0.923	0.896	0.711	میانگین دقت

نتیجه گیری:

در این مقاله یک پایگاه داده از تصاویر موجودات دریایی ایجاد شد و انواع روش‌های بازیابی مبتنی بر محتوای تصویر که شامل استخراج ویژگی‌های رنگ، شکل و بافت می‌باشند، بر روی این تصاویر اعمال گردید. به منظور افزایش دقت بازیابی تمامی تصاویر با استفاده از الگوریتم‌های فرا ابتکاری مختلف به صورت خودکار خوشه‌بندی شده‌اند و الگوریتم‌های اصلی بر روی این تصاویر اعمال شدند. نتایج حاصل از معیار ارزیابی دقت و فراخوانی نشان داد که خوشه‌بندی خودکار با استفاده از الگوریتم‌های بهینه‌سازی دارای میانگین دقت بالاتری نسبت به استفاده تنها، از الگوریتم‌های اصلی بازیابی تصویر می‌باشد و در این میان الگوریتم PSO دارای بالاترین دقت بازیابی بود.

منابع:

- C.-H. Lin, H.-Y. Chen and Y.-S. Wu, "Study of image retrieval and classification based on adaptive features using genetic algorithm feature selection," *Expert Syst. Appl.*, vol. 41, no. 15, pp. 6611–6621, 2014.
- Z. Raisi, F. Mohanna, and M. Rezaei, "Applying Content-Based Image Retrieval Techniques to Provide New Services for Tourism Industry," *Int. J. Adv. Netw. ...*, 2014.
- B. Furht, Ed., *Encyclopedia of Multimedia*. Boston, MA: Springer US, 2008.
- S. Hussain and M. Hashmani, "Image retrieval based on color and texture feature using artificial neural network," *Emerg. Trends ...*, 2012.

- S. S. Hiwale and D. Dhotre, "Content-based image retrieval: Concept and current practices," in 2015 International Conference on Electrical, Electronics, Signals, Communication and Optimization (EESCO), 2015, pp. 1–6.
- Y. Rui, T. S. Huang, and S.-F. Chang, "Image Retrieval: Current Techniques, Promising Directions, and Open Issues," *J. Vis. Commun. Image Represent.* vol. 10, no. 1, pp. 39–62, Mar. 1999.
- C.-H. Lin, C.-C. Chen, H.-L. Lee and J.-R. Liao, "Fast K-means algorithm based on a level histogram for image retrieval," *Expert Syst. Appl.*, vol. 41, no. 7, pp. 3276–3283, Jun. 2014.
- Z. Raisi, F. Mohanna, and M. Rezaei, "Content-Based Image Retrieval for Tourism Application Using Handheld Devices'," *IJICTR J.*, 2011.
- M. Huang, H. Shu, Y. Ma, and Q. Gong, "Content-based image retrieval technology using multi-feature fusion," *Opt. - Int. J. Light Electron Opt.*, vol. 126, no. 19, pp. 2144–2148, Oct. 2015.
- C. Singh, "Improving image retrieval using combined features of Hough transform and Zernike moments," *Opt. Lasers Eng.*, vol. 49, no. 12, pp. 1384–1396, Dec. 2011.
- S. M. Elshoura and D. B. Megherbi, "Analysis of noise sensitivity of Tchebichef and Zernike moments with application to image watermarking," *J. Vis. Commun. Image Represent.* vol. 24, no. 5, pp. 567–578, Jul. 2013.
- M. Verma and B. Raman, "Center symmetric local binary co-occurrence pattern for texture, face and bio-medical image retrieval," *J. Vis. Commun. Image Represent.* vol. 32, pp. 224–236, 2015.
- R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Trans. Syst. Man. Cybern.*, vol. 3, no. 6, pp. 610–621, Nov. 1973.
- G.-H. Liu and J.-Y. Yang, "Image retrieval based on the texton co-occurrence matrix," *Pattern Recognit.*, vol. 41, no. 12, pp. 3521–3527, 2008.
- G. H. Liu, L. Zhang, Y. K. Hou, Z. Y. Li, and J. Y. Yang, "Image retrieval based on multi-texton histogram," *Pattern Recognit.*, vol. 43, no. 7, pp. 2380–2389, 2010.
- B. M. Mehtre, M. S. Kankanhalli, and W. F. Lee, "Shape measures for content based image retrieval: A comparison," *Inf. Process. Manag.* vol. 33, no. 3, pp. 319–337, May 1997.
- Y. R. Charles and R. Ramraj, "A novel local mesh color texture pattern for image retrieval system," *AEU - Int. J. Electron. Commun.* vol. 70, no. 3, pp. 225–233, 2016.
- I. Dimitrovski, D. Kocev, S. Loskovska, and S. Eroski, "Improving bag-of-visual-words image retrieval with predictive clustering trees," *Inf. Sci. (Ny)*, vol. 329, pp. 851–865, 2016.

- J. H. Holland, *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: Univ. Michigan Press, 1975.
- J. Kennedy and R. Eberhart, "Particle swarm optimization," in Proc. IEEE Int. Conf. Neural Netw., 1995, pp. 1942–1948
- R. Storn and K. Price, "Differential evolution—A simple and efficient heuristic for global optimization over continuous spaces," *J. Glob. Optim.* vol. 11, no. 4, pp. 341–359, Dec. 1997.
- S. Bandyopadhyay and U. Maulik, "Genetic clustering for automatic evolution of clusters and application to image classification," *Pattern Recognit.*, vol. 35, no. 6, pp. 1197–1208, Jun. 2002.
- M. Omran, A. Salman, and A. Engelbrecht, "Dynamic clustering using particle swarm optimization with application in unsupervised image classification," in Proc. 5th World Enformatika Conf. (ICCI), Prague, Czech Republic, 2005.
- Raisi, Z., & Azarakhsh, J. Content Based Image Retrieval for Marine Life Images Using Ant Colony Optimization Feature Selection.
- Karaboga, Dervis. "Artificial bee colony algorithm." *scholarpedia* 5, no. 3 (2010): 6915.
- E. W. Forgy, "Cluster analysis of multivariate data: Efficiency versus interpretability of classification," *Biometrics*, vol. 21, no. 3, pp. 768–769, 1965.
- J. C. Dunn, "Well separated clusters and optimal fuzzy partitions", *J. Cybern.* vol. 4, pp. 95–104, 1974.
- R. B. Calinski and J. Harabasz, "A dendrite method for cluster analysis," *Commun. Stat.*, vol. 3, no. 1, pp. 1–27, 1974.
- D. L. Davies and D. W. Bouldin, "A cluster separation measure," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 1, no. 2, pp. 224–227, Apr. 1979
- M. K. Pakhira, S. Bandyopadhyay, and U. Maulik, "Validity index for crisp and fuzzy clusters," *Pattern Recognit. Lett.* vol. 37, no. 3, pp. 487–501, Mar. 2004.
- C. H. Chou, M. C. Su, and E. Lai, "A new cluster validity measure and its application to image compression," *Pattern Anal. Appl.*, vol. 7, no. 2, pp. 205–220, Jul. 2004.
- Raisi, Z., & Azarakhsh, J., "Feature Selection Based-On Swarm Particle Optimization and Genetic Algorithms for Image Retrieval", *International Journal of Advanced Biotechnology and Research (IJBR)*, Vol-7, Special Issue-Number5-July, pp907-916, 2016