

دریافت مقاله: ۱۴۰۳/۱۰/۰۵

پذیرش مقاله: ۱۴۰۳/۱۰/۲۹

## ارائه روشی برای خوشه‌بندی اشیاء دریایی با به‌کارگیری رویکرد تشخیص اجتماع در شبکه‌های اجتماعی

علی ریحانیان\*

استادیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه اراک، اراک، ایران

عضو پژوهشکده هوش مصنوعی، دانشگاه اراک، اراک، ایران

پست الکترونیکی: a-reihanian@araku.ac.ir

ابوالقاسم دائی‌چیان

دانشیار گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه اراک، اراک، ایران

عضو پژوهشکده هوش مصنوعی، دانشگاه اراک، اراک، ایران

پست الکترونیکی: a-daeichian@araku.ac.ir

### چکیده

تولید ویژگی برای کشف خصوصیات مذکور، انجام شده است، تا قابلیت وفق‌پذیری بیشتری با کاربردهای مختلف و متفاوت داشته باشد. سپس، با توجه به پتانسیل تئوری گراف، عمل خوشه‌بندی اشیاء دریایی، با به‌کارگیری مباحث مرتبط با حوزه تشخیص اجتماع در شبکه‌های اجتماعی، که ناظر به عمل خوشه‌بندی بر روی گراف‌ها هستند، صورت پذیرفته است. در این تحقیق، عملکرد روش پیشنهادی، با انجام آزمایش بر روی دو مجموعه داده حاوی فایل‌های صوتی مربوط به اشیاء دریایی، بررسی شده است. به منظور ارزیابی عملکرد روش پیشنهادی، از معیار شاخص ژاکارد استفاده شده است. عملکرد روش پیشنهادی، با در نظر گرفتن سه مورد از بهترین الگوریتم‌های تشخیص اجتماع در مرحله چهارم آن، مقایسه شده است. نتایج نشان داده‌اند که روش پیشنهادی توانسته است در بهترین حالت، به مقدار شاخص ژاکارد  $0.923$  و  $0.800$ ، به ترتیب بر روی مجموعه داده‌های اول و دوم، دست پیدا کند. نتایج آزمایش مذکور، نشان از آن دارند که روش خوشه‌بندی

شناسایی و گروه‌بندی وسایل دریایی در مناطق آبی، از اهمیت ویژه‌ای برخوردار است. اکثر تحقیقات در حوزه گروه‌بندی اشیاء دریایی، از رویکرد ناظر استفاده می‌کنند و در نتیجه وابسته به فرایند آموزش بر روی مجموعه داده‌هایی می‌باشند که برچسب طبقه هر عضو، مشخص است. البته فراهم آوردن داده‌های برچسب‌دار، همیشه امکان‌پذیر نیست و در بسیاری از مواقع، مجموعه داده‌های واقعی، فاقد برچسب طبقه هستند. در این مقاله، یک روش جدید خوشه‌بندی اشیاء دریایی، با رویکرد بدون ناظر، ارائه شده است. روش پیشنهادی، شامل ۴ مرحله تولید ویژگی، ایجاد ماتریس‌های شباهت، ایجاد ماتریس شباهت کل و تشخیص اجتماع می‌باشد. عمل خوشه‌بندی، برخلاف عموم روش‌های مشابه، نه با در نظر گرفتن تنها یک خصوصیت از اعضای یک مجموعه داده، بلکه با در نظر گرفتن چندین خصوصیت و با به‌کارگیری چندین الگوریتم

\* نویسنده مسئول

ارائه شده، می‌تواند به نتایج مناسبی دست پیدا کند، و راه حل مناسبی برای خوشه‌بندی اشیاء دریایی ارائه دهد. واژه‌های کلیدی: اشیاء دریایی، تولید ویژگی، ماتریس شباهت، خوشه‌بندی، تشخیص اجتماع

## ۱- مقدمه

اکثر روش‌هایی که به منظور گروه‌بندی اشیاء دریایی<sup>۱</sup>، تا به الان ارائه شدند، روش‌های طبقه‌بندی<sup>۲</sup> می‌باشند [۱]. می‌دانیم که روش‌های طبقه‌بندی، از رویکرد یادگیری با ناظر<sup>۳</sup> [۲] استفاده می‌کنند. در این رویکرد، یک مجموعه داده برچسب‌دار<sup>۴</sup>، به دو بخش تقسیم می‌شود. بخش اول، که حاوی قسمت اعظم مجموعه داده مذکور می‌باشد، به منظور آموزش روش طبقه‌بندی، و بخش دوم، به منظور ارزیابی عملکرد روش مذکور، مورد استفاده قرار می‌گیرد. روش‌های طبقه‌بندی، به خوبی برای مجموعه داده‌های برچسب‌دار عمل می‌کنند، اما نقطه ضعف بزرگ این روش‌ها زمانی آشکار می‌شود که بخواهند یک مجموعه داده فاقد برچسب (مانند اکثر مجموعه داده‌های واقعی) را پردازش کنند. در این حالت، روش‌های طبقه‌بندی، قادر به پردازش چنین مجموعه داده‌ای نخواهند بود، چرا که این روش‌ها، از رویکرد یادگیری با ناظر استفاده می‌کنند، که بر مبنای آن، حتماً بایستی طبقه‌های واقعی یک مجموعه داده، حداقل برای عمل آموزش، مشخص باشند. برای فائق آمدن بر مشکل مذکور، می‌توان روش‌های خوشه‌بندی<sup>۵</sup> را که از رویکرد یادگیری بدون ناظر<sup>۶</sup> [۲، ۳] استفاده می‌کنند، به کار برد. در این روش‌ها، تنها اطلاعات داخلی یک مجموعه داده (مانند اطلاعات مربوط به اعضای مجموعه داده و اطلاعات مربوط به روابط<sup>۷</sup> بین این اعضا)، برای گروه‌بندی اعضای آن، مورد استفاده قرار می‌گیرند، و دیگر نیازی به دانستن برچسب مربوط به گروه واقعی اعضای مجموعه داده

مذکور، نمی‌باشد [۴، ۵]. با توجه به نقطه قوت مطرح شده برای رویکرد یادگیری بدون ناظر، در این مقاله سعی شده است که از قابلیت این رویکرد، استفاده شود، و یک روش خوشه‌بندی برای اشیاء دریایی، معرفی شود. برخلاف عموم روش‌های مشابه، انجام عمل خوشه‌بندی توسط روش پیشنهادی، نه با در نظر گرفتن تنها یک خصوصیت<sup>۸</sup> از اعضای یک مجموعه داده، بلکه با در نظر گرفتن چندین خصوصیت از اعضای مجموعه داده مذکور (با به‌کارگیری چندین الگوریتم تولید ویژگی، برای کشف خصوصیات مذکور)، صورت می‌پذیرد، تا قابلیت وفق‌پذیری<sup>۹</sup> روش مذکور با کاربردهای مختلف و متفاوت، افزایش پیدا کند.

اما پرسشی که در اینجا مطرح می‌شود این مورد می‌باشد که خوشه‌بندی که توسط روش پیشنهادی بر روی مجموعه داده‌ای از اشیاء دریایی صورت می‌پذیرد، به چه نحو عمل می‌کند؟ برای پاسخ به این پرسش، ذکر چند نکته ضروری است. در سال‌های اخیر، تحقیقات بسیاری در حوزه تشخیص اجتماع<sup>۱۰</sup> در شبکه‌های اجتماعی [۶] صورت پذیرفته‌اند، و الگوریتم‌های تشخیص اجتماع بسیاری نیز به منظور شناسایی اجتماعات در شبکه‌های اجتماعی، معرفی شده‌اند، و این فرایند، حوزه تشخیص اجتماع در شبکه‌های اجتماعی را به یکی از داغ‌ترین زمینه‌های تحقیقاتی این سال‌ها، تبدیل کرده است. تشخیص اجتماع، در واقع همان عمل خوشه‌بندی می‌باشد که بر روی شبکه‌های اجتماعی صورت می‌پذیرد، و از آنجایی که عموماً، شبکه‌های اجتماعی، به صورت گراف مدل می‌شوند، می‌توان گفت که تشخیص اجتماع در شبکه‌های اجتماعی، بهمانند عمل خوشه‌بندی بر روی یک گراف، عمل می‌کند. کار با ساختار گراف، انعطاف‌پذیری بالایی را به همراه دارد، و اگر بتوان داده‌های موجود در یک مجموعه داده را به صورت یک گراف مدل کرد، آنگاه می‌توان اطلاعات مختلفی را از گراف مذکور استخراج کرد، اطلاعاتی که شاید امکان استخراج آن‌ها، در حالت عادی،

8-Attribute

9-Adaptability

10-Community detection

1-Marine objects

2-Classification

3-Supervised learning

4-Labeled Data set

5-Clustering

6-Unsupervised learning

7-Relations

گراف‌های در نظر گرفته شده در فرایند روش پیشنهادی در ادامه تحقیق، ابتدا در بخش دوم، مقدمه‌ای از بحث تشخیص اجتماع، مطرح شده، و در بخش سوم، برخی از پژوهش‌های مرتبط با موضوع تحقیق، بررسی می‌شوند. سپس، در بخش چهارم، روش پیشنهادی تحقیق، معرفی شده، و در بخش پنجم، آزمایش صورت‌پذیرفته به منظور بررسی عملکرد روش پیشنهادی، مطرح شده، و نتایج این آزمایش، ارائه شده و تحلیل و بررسی می‌شوند. در نهایت، در بخش ششم، یک جمع‌بندی از فرایند تحقیق، ارائه شده، و مجموعه‌ای از کارهایی که می‌توان در پژوهش‌های آتی، در راستای تحقیق پیش رو، انجام داد، مطرح می‌شوند.

## ۲- مقدمه‌ای از بحث تشخیص اجتماع

یک شبکه اجتماعی را می‌توان به عنوان یک ساختار اجتماعی بین بازیگران مختلف در نظر گرفت [۹]. تحقیقات انجام شده در راستای شناخت شبکه‌ها، منجر به استفاده از مفاهیم ریاضی گراف برای توصیف آنها شد [۱۰]. در گراف یک شبکه اجتماعی، گره‌ها یا رئوس، نقش بازیگران شبکه اجتماعی مربوطه را ایفا می‌کنند، و یال‌ها یا لبه‌ها، نمایانگر ارتباطات بین این بازیگران خواهند بود. گراف  $G = \{V, E\}$  یک شبکه را در نظر بگیرید. ساختار این گراف، می‌تواند توسط یک ماتریس  $n \times n$  (که  $n$ ، تعداد گره‌ها در شبکه مربوطه را نشان می‌دهد)، به نام ماتریس مجاورت  $A$  توصیف شود، به طوری که اگر گره‌های  $i$  و  $j$  به یکدیگر متصل باشند (در گراف  $G$ ، بین دو گره  $i$  و  $j$ ، یال وجود داشته باشد)، درایه  $A_{ij}$  از ماتریس مذکور، برابر ۱، و در غیر این صورت، برابر صفر باشد [۱۰].

یکی از مباحث مهم در زمینه تحلیل شبکه‌های اجتماعی (SNA)<sup>۱۲</sup>، تشخیص اجتماعات موجود در این شبکه‌ها می‌باشد. یک اجتماع، می‌تواند به عنوان گروهی از گره‌ها در نظر گرفته شود که تعاملات<sup>۱۴</sup> بیشتری بین اعضای این گروه، نسبت به اعضای این گروه و دیگر اعضای شبکه،

از مجموعه داده مذکور، وجود نداشته باشد، یا به سختی بتوان چنین اطلاعاتی را استخراج کرد. حال، می‌توان سوال پرسیده شده در ابتدای پاراگراف را بدین صورت پاسخ گفت که با توجه به نقاط قوت استفاده از ساختار گراف، عمل خوشه‌بندی اشیاء دریایی در روش پیشنهادی، با به‌کارگیری مباحث مرتبط با حوزه تشخیص اجتماع در شبکه‌های اجتماعی، که ناظر به عمل خوشه‌بندی بر روی گراف‌ها هستند، صورت می‌پذیرد. به منظور آشنایی بیشتر با بحث تشخیص اجتماع، در زیربخش ۲-۱، مقدمه‌ای اجمالی از این بحث مطرح خواهد شد [۷، ۸].

در تحقیق پیش رو، اهداف کلی زیر دنبال می‌شوند:

- ارائه یک روش، به منظور گروه‌بندی اشیاء دریایی
- عدم نیاز روش پیشنهادی به فرایند آموزش با داده‌های برچسب‌دار، با در پیش گرفتن رویکرد یادگیری بدون ناظر
- بهره بردن از منافع استفاده از ساختار گراف در روش پیشنهادی، با به‌کارگیری مباحث مربوط به حوزه تشخیص اجتماع در شبکه‌های اجتماعی
- منعطف بودن روش پیشنهادی و توانایی آن در بررسی مجموعه داده‌های حاوی انواع مختلفی از اشیاء دریایی
- انجام عمل خوشه‌بندی توسط روش پیشنهادی، با در نظر گرفتن چندین خصوصیت از اعضای یک مجموعه داده، به منظور افزایش قابلیت وفق‌پذیری آن با کاربردهای مختلف و متفاوت

• در راستای رسیدن به اهداف مذکور، در این تحقیق، نوآوری‌هایی به شرح زیر صورت پذیرفته‌اند:

- ارائه یک روش جدید، به منظور خوشه‌بندی اشیاء دریایی، با به‌کارگیری مباحث مرتبط با حوزه تشخیص اجتماع در شبکه‌های اجتماعی

- ارائه یک سازوکار جدید، به منظور یافتن شباهت<sup>۱۱</sup> میان اعضای یک مجموعه داده حاوی اطلاعات مربوط به اشیاء دریایی، با ترکیب نتایج تولید ویژگی حاصل از اعمال چندین الگوریتم تولید ویژگی بر روی مجموعه داده مذکور، و استفاده از شباهت‌های مذکور، به عنوان وزن یال‌های

12-Adjacency matrix

13-Social Network Analysis

14-Interactions

11-Similarity


مشهورترین معیار ارزیابی اجتماعات کشفشده توسط یک الگوریتم تشخیص اجتماع، تابع پیمانی<sup>۱۶</sup> می باشد. این تابع، که با  $Q$  نشان داده می شود، اولین بار در کدام منبع؟؟؟؟ لطفاً منبع را ذکر کنید معرفی شد. در حال حاضر، بسیاری از محققین، از تابع پیمانی برای ارزیابی عملکردهای روش های تشخیص اجتماعی که در تحقیقاتشان به کار می گیرند، استفاده می کنند. ورودی تابع پیمانی، شبکه مربوطه و تمامی اجتماعات شناسایی شده آن توسط یک روش تشخیص اجتماع بوده، و خروجی آن، یک عدد حقیقی بین -۱ و ۱ می باشد. تابع پیمانی به صورت زیر تعریف می شود [۱۳]:

$$Q = \frac{1}{2m} \sum_{i,j} \left[ A_{ij} - \frac{k_i k_j}{2m} \right] \delta(C_i, C_j)$$

که در آن،  $A$ ، ماتریس مجاورت شبکه مربوطه،  $k_i = \sum A_{ij}$  درجه گره  $i$ ،  $C_i$  نمایانگر اجتماعی است که گره  $i$  به آن نسبت داده شده است، و  $m = \frac{1}{2} \sum_{i,j} A_{ij}$  تعداد کل یال ها در شبکه مربوطه را مشخص می کند. علاوه بر این، مقدار تابع  $\delta(u, v)$  برابر ۱ خواهد بود، اگر  $u = v$  باشد، و در غیر این صورت، برابر صفر خواهد بود.

اگر یک روش تشخیص اجتماع بتواند طوری یک شبکه را افراز بندی کند که مقدار پیمانی برای آن، نزدیک به ۱ محاسبه شود، این امر نشان از عملکرد مناسب آن روش در شناسایی ساختار اجتماع شبکه مربوطه خواهد داشت. اما باید به این نکته اشاره کرد که مقدار مناسب برای تابع پیمانی در شبکه های مختلف، متفاوت می باشد. برای مثال، شاید مقدار تابع پیمانی در یک شبکه، هیچگاه بیشتر از ۰/۴ نشود. بنابراین اگر یک روش تشخیص اجتماع طوری یک شبکه را افراز بندی کند که مقدار پیمانی برای آن، نزدیک به ۰/۴ محاسبه شود، نمی توان گفت که اجتماعات تشخیص داده شده توسط روش مذکور، مناسب نیستند، زیرا ممکن است که ۰/۴، بیشترین مقدار تابع پیمانی باشد که یک روش تشخیص اجتماع بتواند در شبکه مزبور به آن

وجود دارد؛ مانند یک گروه از دوستان در یک شبکه اجتماعی یا گروهی از صفحات وب به هم پیوند داده شده در شبکه جهانی وب [۱۱]. شکل (۱)، نمونه ای از اجتماعات تشخیص داده شده در یک شبکه را نشان می دهد.



شکل (۱): نمونه ای از اجتماعات تشخیص داده شده در یک شبکه [۱۲]

## ۲-۱- بررسی تابع پیمانی، به عنوان مشهورترین معیار سنجش کیفیت تشخیص اجتماع

سوال مهمی که در اینجا مطرح می شود این مورد می باشد که چگونه می توان عملکردهای الگوریتم های تشخیص اجتماع را ارزیابی کرد؟ به عبارت دیگر، چگونه می توان مناسب ترین افراز را در بین خروجی های الگوریتم های مختلف تشخیص اجتماع، تعیین کرد؟ برای رسیدن به پاسخ این سوالات، لازم است که یک معیار کمی برای ارزیابی میزان مناسب بودن یک افراز بندی از یک گراف تعیین شود. بدین منظور، می توان از یک تابع کیفیت<sup>۱۷</sup> استفاده کرد. تابع کیفیت، تابعی می باشد که برای هر افراز از یک گراف، مقداری را محاسبه می کند. در این حالت، می توان افرازا را بر مبنای مقادیر محاسبه شده برای آن ها توسط تابع کیفیت، رتبه بندی کرد. بنابراین می توان گفت که در بین خروجی های الگوریتم های مختلف تشخیص اجتماع، افرازی که بالاترین مقدار را به دست آورد، مناسب ترین افراز خواهد بود [۶]. از این رو، الگوریتمی که افراز مذکور را تولید کند، بهترین عملکرد را در میان دیگر رقبا، به نمایش خواهد گذاشت.

ابزارهایی همچون DEMON، LOFAR، صوت خام<sup>۱۹</sup> و طیف‌نگار<sup>۲۰</sup>، استفاده میکند. این ابزارها (تکنیک‌ها) مبتنی بر روش‌های قطعی<sup>۲۱</sup> هستند، که این روش‌ها، خود مبتنی بر اقیانوس‌شناسی<sup>۲۲</sup>، مدلسازی سونار<sup>۲۳</sup> و پردازش سیگنال کلاسیک، می‌باشند [۱۵]. انجام کارهای طبقه‌بندی، با اتکای صرف به اپراتور سونار، نیازمند نظارت پیوسته و مهارت نیروی انسانی، می‌باشد. همچنین، این مورد می‌تواند تحت تاثیر شرایط محیط زیر آب، نسبت سیگنال به نوفه (SNR)<sup>۲۴</sup> پایین، انتشار چند مسیره صوت<sup>۲۵</sup> و حالت و شرایط فیزیکی انسان، قرار گیرد. از طرف دیگر، آموزش منابع انسانی، بسیار وقت‌گیر و گران است، چرا که نیازمند دسترسی تمام‌وقت به ابزارهای مرتبط، می‌باشد. با توجه به محدودیت‌های مذکور، و مزایای منحصر به فرد روش‌های مبتنی بر هوش مصنوعی در مواجهه با مسائل بازشناسی با محیط‌های پیچیده و دانش پیش‌زمینه مبهم، و همچنین، موفقیت روش‌های مبتنی بر هوش مصنوعی در حوزه‌های مشابه، محققین متعددی اقدام به استفاده از چنین روش‌هایی، به منظور طبقه‌بندی اصوات زیر آب<sup>۲۶</sup>، نمودند [۱۶]. روش‌های طبقه‌بندی اصوات زیر آب مبتنی بر هوش مصنوعی را می‌توان به دو گروه روش‌های کلاسیک مبتنی بر یادگیری ماشین و روش‌های مبتنی بر یادگیری عمیق، تقسیم کرد [۱۷].

روش‌های یادگیری ماشین، به سبب سادگی، کارایی و پیاده‌سازی به نسبت آسان، به طور گسترده‌ای جهت بازشناسی اهداف صوتی زیر آب<sup>۲۷</sup>، به کار گرفته شدند [۱۸-۲۰]. ساختار استاندارد آنها، مستلزم این مورد می‌باشد که ویژگی‌های استخراج شده، به عنوان ورودی، به الگوریتم‌های یادگیری ماشین داده شوند، تا این الگوریتم‌ها بتوانند بر اساس شباهت ویژگی‌های نمونه‌ها،

برسد. همچنین، لازم به ذکر است که مقدار تابع پیمانی در زمانی که تمامی گره‌های یک شبکه با یکدیگر تشکیل یک اجتماع را بدهند (شبکه، تنها از یک اجتماع شامل تمام گره‌های آن، تشکیل شده باشد)، برابر صفر خواهد بود. از طرف دیگر، برای افزایش از یک شبکه که در آن، هر گره به تنهایی تشکیل یک اجتماع را بدهد، مقداری منفی برای تابع پیمانی محاسبه خواهد شد. در حالتی که برای یک شبکه، هیچ افزایشی با مقدار مثبت تابع پیمانی وجود نداشته باشد، می‌توان گفت که آن شبکه، هیچ ساختار اجتماعی ندارد [۶] پس از آن‌که تابع پیمانی در [۱۳] معرفی شد، حالات تعمیم یافته‌ای از این تابع کیفیت، در تحقیقات و پژوهش‌های مختلف، پیشنهاد شدند. برای مثال، تابع پیمانی، به راحتی می‌تواند به منظور سنجش کیفیت تشخیص اجتماع در گراف‌های وزن‌دار، تعمیم داده شود. در این حالت، این تابع می‌تواند از رابطه زیر محاسبه می‌شود [۱۴]:

$$Q_w = \frac{1}{w} \sum_{ij} (W_{ij} - \frac{S_i S_j}{w}) \delta(C_i, C_j)$$

که در آن،  $S_i$  و  $S_j$  بیان‌گر قدرت گره‌های  $i$  و  $j$  می‌باشند. قدرت یک گره، جمع وزن‌های یال‌های مجاور آن گره می‌باشد. همچنین،  $w$ ، برابر جمع وزن‌های تمامی یال‌های موجود در شبکه مربوطه می‌باشد.  $W_{ij}$  نیز، وزن یال  $ij$  می‌باشد. همچنین، اگر گره‌های  $i$  و  $j$  در یک اجتماع باشند  $(C_i = C_j)$ ، مقدار تابع  $\delta$ ، برابر ۱، و در غیر این‌صورت برابر صفر خواهد بود.

### ۳- بررسی برخی پژوهش‌های مرتبط

در این بخش، به بررسی برخی پژوهش‌های انجام شده در حوزه‌های مرتبط با موضوع تحقیق، پرداخته می‌شود. طبقه‌بندی سنتی اصوات حاصل از کشتی‌ها در زیر آب<sup>۲۸</sup>، هنوز اساساً به تخصص اپراتور سونار<sup>۲۹</sup> بستگی دارد. اپراتور سونار، به منظور طبقه‌بندی اصوات، از

19-Raw audio  
20-Spectrogram  
21-Deterministic methods  
22-Oceanography  
23-Sonar modeling  
24-Signal-to-Noise Ratio  
25-Multi-path of sound propagation  
26-Underwater sound classification  
27-Underwater Acoustic Target Recognition

17-Classic underwater vessel sound classification  
18-Sonar operator

به یافتن مرز(های) طبقه‌بندی، بپردازند [۲۱]. در ادامه، به بررسی برخی از جدیدترین پژوهش‌هایی می‌پردازیم، که از روش‌های کلاسیک مبتنی بر یادگیری ماشین، به منظور طبقه‌بندی اصوات زیر آب، استفاده کردند [۱۶، ۲۱].

در بسیاری از تحقیقات، این مورد اثبات شد که ترکیب ماشین بردار پشتیبان (SVM) با ویژگی‌های منفرد<sup>۲۸</sup> (ویژگی‌های حاصل از یک الگوریتم استخراج ویژگی)، می‌تواند منجر به نتایج طبقه‌بندی مناسبی گردد [۲۲-۲۶]. با این وجود، این مطالعات، عملکرد رویکردهای مبتنی بر ویژگی‌های چندبعدی<sup>۲۹</sup> را بررسی نکردند. لیو و همکاران [۲۷]، اثبات کردند که استفاده از ویژگی‌های چندگانه<sup>۳۰</sup> (ویژگی‌های حاصل از چندین الگوریتم تولید ویژگی)، می‌تواند منجر به نتایج بهتری بر روی مجموعه داده‌های صوتی واقعی گردد. لی و همکاران [۲۸]، ویژگی‌های آنتروپی پراکندگی چندمقداری مرکب پالایش شده<sup>۳۱</sup> (RC-MDE) را برای نوفه حاصل از کشتی‌ها، معرفی کردند، و از الگوریتم K نزدیکترین همسایگان<sup>۳۲</sup> (KNN) به منظور بازشناسی هدف<sup>۳۳</sup>، استفاده کردند. آزمایش‌های انجام شده بر روی مجموعه داده حاوی چهار طبقه از کشتی‌ها، اثبات کرد که روش ارائه شده، می‌تواند به طور موثری، الگوهای ضمنی نهفته در سیگنال‌های زیر آب<sup>۳۴</sup> را کشف کند. جین و همکاران [۲۹]، به استخراج ویژگی عملکرد حالت ذاتی (IMF)<sup>۳۵</sup>، بر اساس فرکانس مرکزی سیگنال هدف و شدت انرژی، پرداختند. سپس، به منظور بازشناسی کشتی‌های نزدیک ساحل، این ویژگی، به الگوریتم K نزدیکترین همسایگان (KNN)، داده شد. نتایج آزمایش‌های انجام شده به منظور بررسی روش پیشنهادی، نشان از موثر بودن این روش داشتند. قریشی و همکاران [۳۰]، به پیش‌پردازش سیگنال‌های زیر آب حاصل از سونار، به منظور جداسازی

خصوصیات حیاتی همچون شدت سیگنال<sup>۳۷</sup>، فرکانس و زوایای بازتاب<sup>۳۸</sup>، از آنها، پرداختند. با جمعیت تکنیک‌های انتخاب ویژگی، قریشی و همکاران توانستند با موفقیت، عمل طبقه‌بندی دوکلاسه (باینری) را با استفاده از مدل‌های رگرسیون خطی<sup>۳۹</sup> (مانند رگرسیون لجستیک<sup>۴۰</sup>)، انجام دهند. موسوی‌پور و موسوی [۳۱]، یک پرسپترون چندلایه<sup>۴۱</sup> (MLP)، به منظور شناسایی حضور یک هدف دریایی، ارائه دادند. پارامترهای MLP ارائه شده، با استفاده از الگوریتم سنجاقک (DA) ترکیبی<sup>۴۲</sup>، تنظیم شد. مدل پیشنهادی، برای عمل طبقه‌بندی دوکلاسه (باینری)، استفاده شد. نکته‌ای که در مورد استفاده از MLP، جهت طبقه‌بندی اشیاء دریایی، بایستی در نظر گرفته شود، این مورد می‌باشد که در صورتی که تعداد داده‌های مجموعه داده موردنظر، زیاد باشد (با کلان‌داده سروکار داشته باشیم)، و در عین حال، تعداد لایه‌های MLP را کم در نظر بگیریم (MLP)، معماری کم‌عمقی داشته باشد)، احتمالاً به مشکل محدودیت در قابلیت تعمیم‌پذیری، برخوردیم خورد. ماهاله و همکاران [۳۲]، با استفاده از ترکیب الگوریتم‌های تحلیل مولفه اصلی (PCA) و K میانگین (K-means)، به عمل طبقه‌بندی چهار نوع صوت ماهی، پرداختند. الگوریتم تحلیل مولفه اصلی (PCA)، به منظور کاهش بعد، و همچنین، الگوریتم K میانگین (K-means)، به منظور خوشه‌بندی، استفاده شد.

به طور کلی، کاربرد موفق روش‌های مختلف یادگیری ماشین، قابلیت آنها در پردازش قابل قبول داده‌های صوتی زیر آب را اثبات کرد، که این امر، منجر به انگیزه مضاعف در توسعه مبتنی بر یادگیری سیستم‌های بازشناسی اهداف صوتی زیر آب شد. این پیشرفت‌ها، علاوه بر فراهم آوردن بینشی ارزشمند در پردازش داده‌های زیر آب، یک مبنای نظری مستحکم برای روش‌های مبتنی بر یادگیری عمیق، ایجاد کردند [۲۱]. مدل‌های خروجی

28-Support Vector Machine

29-Individual features

30-Multidimensional features

31-Multiple features

32-Refined Composite Multi-scale Dispersion Entropy

33-K-Nearest Neighbors

34-Target recognition

35-Underwater signals

36-Intrinsic Mode Function

37-Signal intensity

38-Reflection angles

39-Linear Regression

40-Logistic Regression

41-Multi Layer Perceptron

42-Hybrid Dragonfly Algorithm

روش‌های مبتنی بر یادگیری ماشین، نسبت به مدل‌های خروجی روش‌های مبتنی بر یادگیری عمیق، معمولاً در مدت‌زمان کمتری، آموزش داده می‌شوند. با این وجود، روش‌های مبتنی بر یادگیری ماشین، ممکن است که با چالش‌هایی همچون تنزل عملکرد<sup>۴۳</sup>، مواجه شوند، و به دلیل محدودیت قابلیت بازنمایی و تعمیم‌پذیری<sup>۴۴</sup>، نتوانند دقت<sup>۴۵</sup> مناسب را در مواجهه با مجموعه داده‌های بزرگ، از خود نشان دهند [۳۳]. یکی دیگر از محدودیت‌های روش‌های مبتنی بر یادگیری ماشین، عدم توانایی آنها در بهبود عملکرد طبقه‌بندی، حتی با افزودن داده‌های آموزشی بیشتر، می‌باشد. علاوه بر این، تجربه نشان داده است که دقت روش‌های مبتنی بر یادگیری ماشین، در محیط‌های پرتن<sup>۴۶</sup>، پایین خواهد بود [۱۶].

روش‌های یادگیری عمیق، به عنوان زیرمجموعه‌ای از روش‌های یادگیری ماشین، قادر به یادگیری بازنمایی‌های عمیق از سیگنال‌های صوتی پیچیده، با استفاده از شبکه‌های عصبی عمیق (DNNs)<sup>۴۷</sup>، می‌باشند. شبکه‌های عصبی عمیق، که متشکل از انبوهی از لایه‌ها می‌باشند، به طور خاص، در استخراج خودکار ویژگی‌های سلسله‌مراتبی<sup>۴۸</sup> از داده‌های صوتی، موثر می‌باشند. تحقیقات اخیر، به طور گسترده‌ای به بررسی روش‌های بازشناسی اهداف صوتی زیر آب مبتنی بر یادگیری عمیق، پرداختند، و اثبات کردند که این روش‌ها، به دلیل استفاده از اطلاعات سطح بالای<sup>۴۹</sup> نهفته در سیگنال‌های صوتی، عملکرد بهتری را نسبت به طبقه‌بندی‌های مبتنی بر یادگیری ماشین، از خود نشان می‌دهند [۳۴، ۳۵]. روش‌های بازشناسی اهداف صوتی زیر آب، به طور موثری، شبکه‌های عصبی مختلف را، به منظور طبقه‌بندی اهداف زیر آب، به کار می‌گیرند. با تقلید از ساختار عصبی مغز انسان، روش‌های یادگیری عمیق، به ساختارهای چند لایه، جهت یادگیری الگوهای انتزاعی

عمیق درون داده‌ها، متکی هستند. بر اساس اصول یادگرفته شده، این روش‌ها می‌توانند با تحلیل و استدلال، خروجی نمونه‌های نادیده<sup>۵۰</sup> را پیش‌بینی کنند [۲۱]. سیستم‌های بازشناسی اهداف صوتی زیر آب مبتنی بر یادگیری عمیق، که در ابتدا ارائه می‌شدند، به لحاظ منابع محاسباتی (به ویژه حافظه GPU)، محدود بودند، که این امر، آموزش سریع و با ثبات<sup>۵۱</sup> چنین سیستم‌هایی را بسیار سخت میکرد. با این وجود، در ابتدای قرن ۲۱، پیشرفت‌های مبتنی بر فناوری قابل ملاحظه‌ای، همچون افزایش قدرت محاسباتی GPUها، صورت پذیرفت. در نتیجه این پیشرفت‌ها، امکان استفاده از روش‌های پیشرفته یادگیری عمیق، حاصل شد، که این امر، باعث پیشرفت قابل ملاحظه‌ای در بازشناسی مبتنی بر یادگیری اهداف صوتی زیر آب، شد [۲۱]. در ادامه، به بررسی برخی از جدیدترین پژوهش‌هایی می‌پردازیم که از روش‌های مبتنی بر یادگیری عمیق، به منظور طبقه‌بندی اصوات زیر آب، استفاده کردند [۱۶، ۲۱].

کی و همکاران [۳۶]، از واحدهای بازگشتی دروازه‌ای (GRUs)<sup>۵۲</sup>، به منظور استخراج ویژگی‌های ریزدانه<sup>۵۳</sup> از طیف‌نگارهای صوتی<sup>۵۴</sup>، استفاده کردند، و به عملکرد بازشناسی مناسبی روی داده‌های واقعی اقیانوس، دست پیدا کردند. لازم به ذکر است که واحدهای بازگشتی دروازه‌ای (GRUs)، نوعی از شبکه‌های عصبی بازگشتی (RNNs)<sup>۵۵</sup> می‌باشند. یائو و همکاران [۳۷]، از ResNet18 و ویژگی‌های استخراج شده با استفاده از الگوریتم ضرایب کپسترال فرکانس مل (MFCC)<sup>۵۶</sup>، به منظور طبقه‌بندی سیگنال‌های حاصل از کشتی‌ها، استفاده کردند. همچنین، در مطالعه مذکور، افزایش داده‌ها<sup>۵۷</sup>، با استفاده از شبکه مولد هم‌آوردی (GAN)<sup>۵۸</sup>، صورت پذیرفت. نتایج روش پیشنهادی، با روش‌هایی همچون ماشین بردار پشتیبان

50-Unseen samples

51-Stable

52-Gated Recurrent Units

53-Fine-grained

54-Acoustic Spectrograms

55-Recurrent Neural Networks

56-Data augmentation

57-Generative Adversarial Network

43-Performance degradation

44-Representation and generalization capability

45-Accuracy

46-Areas with high reverberations

47-Deep Neural Networks

48-Hierarchical features

49-High-level information

معرفی کردند، که شبکه‌های زیرساختی چندشاخه<sup>۷۰</sup> را با ماژول‌های توجه هم‌آمیختی<sup>۷۱</sup>، ترکیب میکند. این ماژول‌ها، به صورت انتخابی، به اطلاعات سراسری، وزن اختصاص میدهند، و بنابراین، به طور تطبیقی، اطلاعات کلیدی را در داخل طیف‌نگارهای صوتی، به منظور ارتقاء بالقوه عملکرد طبقه‌بندی، فیلتر می‌کنند. چن و همکاران [۴۵]، از ترکیب چهار ویژگی مبتنی بر تحلیل زمان-فرکانس، به عنوان ورودی یک شبکه مبتنی بر شبکه عصبی هم‌آمیختی (CNN)، استفاده کردند. در این تحقیق، یک مدل مبتنی بر کدگذار کدگشا<sup>۷۲</sup> پیشنهاد شد، که شامل چهار شبکه موازی در کدگذار، می‌باشد، که هر یک از این شبکه‌ها، مربوط به یک نوع از ویژگی‌ها می‌باشند. ویژگی‌ها، در لایه میانی شبکه، ترکیب می‌شوند. رن و همکاران [۴۶]، یک سیستم طبقه‌بندی صوت زیر آب مبتنی بر یادگیری با مرحله پیشین یادگیرنده<sup>۷۳</sup>، با نام UALF، معرفی کردند، که می‌تواند به طور خودکار، ویژگی‌های اصوات زیر آب را از نقطه‌نظرات مختلف، استخراج کند، و همچنین، ماژول‌هایی را برای استخراج ویژگی و طبقه‌بندی، برای سناریوهای مختلف، به کار گیرد. در تحقیق مذکور، ادعا شده است که روش پیشنهادی، از سیستم شناختی<sup>۷۴</sup> انسان، تقلید میکند. تیان و همکاران [۴۷]، مدلی ارائه دادند که سیگنال‌های زمانی را به همراه ویژگی‌های مبتنی بر تحلیل زمان-فرکانس، به عنوان ورودی، دریافت میکند. در این تحقیق، یک شبکه عصبی عمیق پسمانده چندمقیاسی (MSRDN)<sup>۷۵</sup> سبک‌وزن، به کمک تکنیک‌های طراحی شبکه سبک‌وزن، طراحی شد. علاوه بر این، یک سازوکار آموزش همگام<sup>۷۶</sup>، به منظور آموزش مدل، اتخاذ شد. در این تحقیق، ادعا شد که روش پیشنهادی، عملکرد مناسبی را در طبقه‌بندی اصوات زیر آب مربوط به دو مجموعه داده محک<sup>۷۷</sup>، از خود نشان میدهد. الوثانی و همکاران [۴۸]، مدلی شامل

(SVM) و شبکه عصبی هم‌آمیختی (CNN)<sup>۷۸</sup>، مقایسه شد. ینگ و همکاران [۳۸]، به منظور کاهش هزینه محاسبات و بهبود دقت<sup>۷۹</sup>، از ResNet10 بجای ResNet18 استفاده کردند. در این تحقیق، ویژگی‌های سه بعدی حاصل از الگوریتم ضرایب کپسترال فرکانس مل (MFCC)، به عنوان ورودی، در نظر گرفته شدند. کای و همکاران [۳۹]، از Xception بهینه شده با هم‌آمیختی‌های عمیق (DW)<sup>۸۰</sup>، به منظور توسعه یک شبکه عصبی عمیق چندشاخه<sup>۸۱</sup>، که بتواند اهداف زیر آب را بازشناسی کند، استفاده کردند. لازم به ذکر است که Xception، نوع دیگری از شبکه‌های Inception، می‌باشد. رویکرد پیشنهادی، Xception را به منظور شناسایی ویژگی‌های جفت طیف خطی<sup>۸۲</sup>، با دیگر شاخه‌ها، شامل MobileNet و DenseNet، جمع کرد. روش پیشنهادی، به دقت‌های بالا در بازشناسی شش طبقه از اصوات زیستی دریایی<sup>۸۳</sup>، دست پیدا کرد. با در نظر گرفتن محدودیت‌های سخت‌افزاری و نیازمندی‌های بیدرنگ<sup>۸۴</sup>، طیفی از شبکه‌های عصبی هم‌آمیختی سبک‌وزن<sup>۸۵</sup> [۴۰-۴۲]، با قابلیت‌های پردازش مستحکم<sup>۸۶</sup> ویژگی به صورت بیدرنگ، به منظور بازشناسی اهداف صوتی زیر آب، معرفی شدند. جین و زنگ [۴۳]، با ترکیب شبکه عصبی هم‌آمیختی (CNN) و سازوکار مبتنی بر توجه<sup>۸۷</sup>، مدلی را به منظور طبقه‌بندی اشیاء دریایی، ارائه دادند. در این تحقیق، سیگنال زمانی خام، به عنوان ورودی مدل، در نظر گرفته شد. یک سازوکار توجه کانالی<sup>۸۸</sup> و یک سازوکار توجه زمانی<sup>۸۹</sup>، به منظور استخراج اطلاعات در بعد کانال و در بعد زمان، در مدل، تعبیه شدند. نتایج عملکرد مدل پیشنهادی، بر روی مجموعه داده‌ای که توسط خود محققین جمع‌آوری شد، گزارش شدند. ونگ و همکاران [۴۴]، مدلی به نام AMNet

58-Convolutional Neural Network

59-Accuracy

60-Depth-Wise convolution

61-Multi-branch

62-Line spectral pair

63-Marine biological sounds

64-Real-time

65-Lightweight

66-Robust

67-Attention-based mechanism

68-Channel Attention mechanism

69-Temporal Attention mechanism

70-Multi-branch backbone networks

71-Convolutional Attention modules

72-Encoder Decoder

73-Learnable Front-End

74-Cognitive system

75-Multi-Scale Residual Deep Neural network

76-Synchronous training mechanism

77-Benchmark

شبکه‌های عصبی هم‌آمیختی (CNNs) و مبدل‌های سنتی، در یادگیری ویژگی‌های جداساز اهداف متحرک موجود در دو مجموعه داده واقعی مربوط به اقیانوس، از خود نشان داد. یائو و همکاران [۵۵]، به ترکیب MobileNet با معماری مبدل، به منظور طراحی MobileViT، پرداختند. این مدل، به طور موثری، اطلاعات ادراکی سراسری و محلی سیگنال‌های صوتی زیر آب را، با اندک پیچیدگی جمع می‌کند.

با افزایش اندازه داده‌ها (بزرگ شدن مجموعه داده‌ها)، مدل‌هایی که دارای معماری عمیق هستند، بهتر از مدل‌های کم‌عمق (مانند مدل‌های یادگیری ماشین)، عمل می‌کنند [۵۶]، [۵۷]. علاوه بر این، قابلیت استخراج ویژگی روش‌های مبتنی بر معماری عمیق، مستحکم‌تر می‌باشد. در حالت کلی، در تحقیقات مختلف، عمدتاً سازوکار آموزش با نظارت، به منظور طبقه‌بندی اصوات زیر آب، به کار گرفته می‌شود [۱۶]. روش‌های مختلف مبتنی بر یادگیری عمیق، قادر به استفاده از اطلاعاتی که در ساختار متغیر با زمان سیگنال‌های صوتی وجود دارد، نمی‌باشند [۵۸]. علاوه بر این، چنین روش‌هایی، نیازمند حجم بالایی از داده‌های برچسب‌دار می‌باشند، تا بتوانند به منظور رسیدن به نتایج دقیق، بهتر آموزش داده شوند. در شرایطی که مجموعه داده‌های برچسب‌دار کوچکی در اختیار باشند، ممکن است که چنین روش‌هایی، به بیش‌برازش<sup>۸۷</sup> برسند [۱۶].

همان‌طور که مشاهده شد، روش‌هایی که در این بخش بررسی شدند، روش‌هایی هستند که به منظور گروه‌بندی اشیاء دریایی، به کار می‌روند. عموم روش‌های مذکور، از رویکرد با ناظر استفاده می‌کنند، و بنابراین، وابسته به فرایند آموزش بر روی مجموعه داده‌هایی می‌باشند که برچسب طبقه هر عضو آنها، مشخص باشد. اما اگر به قضیه گروه‌بندی اشیاء دریایی، از منظر کاربردی نگریسته شود، می‌توان پی به این مطلب برد که فراهم آوردن داده‌های برچسب‌دار، همیشه امکان‌پذیر نمی‌باشد، و در بسیاری از مواقع، نیاز به بررسی مجموعه داده‌های

دو معماری جدید، ارائه دادند. اولین معماری، مبتنی بر الگوریتم استخراج ویژگی ضرایب کپسترال فرکانس مل (MFCC)، می‌باشد. معماری دوم، یک بلوک هم‌آمیختی را به منظور تولید ویژگی‌های زمان-فرکانس، به کار می‌گیرد. ینگ و همکاران [۴۹]، از توجه فضایی<sup>۷۸</sup> در شبکه عصبی هم‌آمیختی (CNN)، به منظور طبقه‌بندی اصوات مربوط به هفت طبقه از پستانداران دریایی، استفاده کردند. در این تحقیق، ویژگی‌های حاصل از تحلیل زمان-فرکانس، به‌عنوان ورودی روش پیشنهادی، در نظر گرفته شدند. فنگ و ژو [۵۰]، مبدل<sup>۷۹</sup> UATR را معرفی کردند. به طور خاص، مدل پیشنهادی، راهبردهای توکنساز<sup>۸۰</sup> سلسله مراتبی را به منظور استخراج واحدهای محاسباتی از طیف‌نگارهای Mel صوتی<sup>۸۱</sup>، به کار می‌گیرد. تبدیل ویژگی بیشتر، از طریق یک سازوکار خودتوجهی چندسر (MHSA)<sup>۸۲</sup>، اثبات می‌کند که مبدل UATR، به دلیل ادراک اطلاعات سراسری و محلی، می‌تواند عملکرد بازشناسی قابل مقایسه با شبکه‌های عصبی هم‌آمیختی (CNNs) مدرن را از خود نشان دهد. با الهام از مبدل طیف‌نگار صوت (AST)<sup>۸۳</sup> در بحث بازشناسی گفتار [۵۱]، لی و همکاران [۵۲]، به تطبیق ساختار این مبدل، به منظور بازشناسی اهداف صوتی زیر آب، پرداختند، که منجر به پیشنهاد مدل مبدل طیف‌نگار (STM)<sup>۸۴</sup> شد. این مدل، عملکرد مناسب‌تری را نسبت به شبکه‌های عصبی هم‌آمیختی (CNNs)، در بازشناسی اهداف صوتی زیر آب، از خود نشان داد. مبدل Swin [۵۳]، به‌عنوان نوع خاصی از مبدل، که از پنجره‌های جابه‌جا شده<sup>۸۵</sup>، به منظور استخراج ویژگی سلسله مراتبی، استفاده می‌کند، توسط وو و همکاران [۵۴]، با نام مبدل Swin زمان-فرکانس (TFST)<sup>۸۶</sup>، به منظور بازشناسی اهداف صوتی زیر آب، به کار گرفته شد. TFST، عملکرد بهتری را نسبت به

78-Spatial Attention

79-Transformer

80-Tokenization

81-Acoustic Mel-spectrograms

82-Multi-Head Self-Attention

83-Audio Spectrogram Transformer

84-Spectrogram Transformer Model

85-Shifted windows

86-Time-Frequency Swin Transformer

دریایی مختلف باشد، خواهد بود. از اینرو، پس از تهیه و آماده سازی مجموعه داده‌ای با مشخصات مذکور، مرحله اول روش پیشنهادی (مرحله تولید ویژگی) آغاز می‌شود. در این مرحله، برای هر یک از اعضای مجموعه داده مذکور، تولید ویژگی با استفاده از ۱۶ الگوریتم تولید ویژگی زیر، صورت می‌پذیرد:

- الگوریتم تحلیل پوش (Envelope Analysis) [۵۹]
- الگوریتم کدگذاری پیش‌بین خطی (LPC) [۶۰]
- الگوریتم آمارگان سیگنال (SigSta) [۶۱]
- الگوریتم آمارگان هیستوگرام سیگنال (SigHisSta) [۶۲]
- الگوریتم ضرایب کپسترال فرکانس مل (MFCC) [۶۳]
- الگوریتم FRQWIDE
- الگوریتم تبدیل کسینوسی گسسته (DCT) [۶۴]
- الگوریتم تحلیل مولفه اصلی (PCA) [۶۵]
- الگوریتم آمارگان طیفی (SpecSta) [۶۶]
- الگوریتم آمارگان هیستوگرام طیفی (SpecHisSta) [۶۷]
- الگوریتم طیفی (Spectral)
- الگوریتم چندکاهنده (Multitaper) [۶۸]
- الگوریتم بانک فیلتر (Filter Bank) [۶۹]
- الگوریتم تحلیل کپستروم (Cepstrum Analysis) [۷۰]

- الگوریتم تبدیل موجک (WT) [۷۱-۷۰]
  - الگوریتم فیلتر شکافی (Notch Filter) [۷۲]
- در واقع، هر یک از الگوریتم‌های تولید ویژگی موجود در لیست بالا، به تعداد کل اعضای موجود در مجموعه داده ورودی، مجموعه ویژگی تولید می‌کنند. برای مثال، اگر مجموعه داده ورودی، شامل  $n$  فایل صوتی مختلف باشد، هر یک از الگوریتم‌های تولید ویژگی مذکور،  $n$  مجموعه مختلف از ویژگی‌ها، تولید خواهند کرد. یعنی در

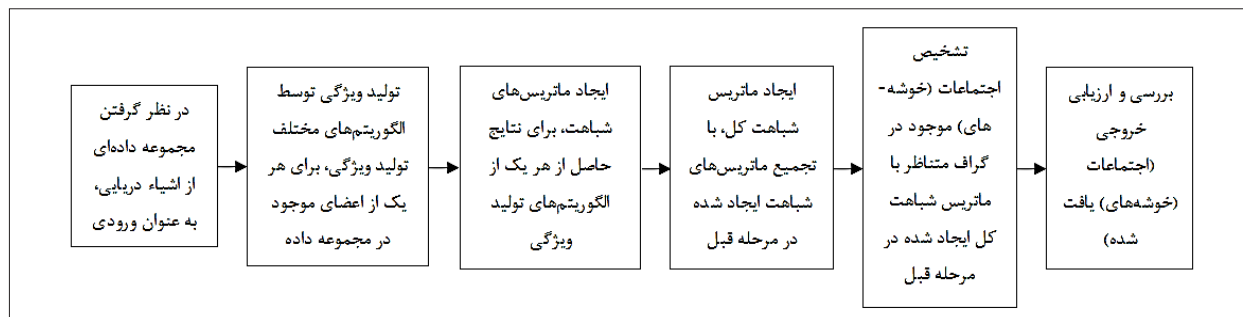
واقعی، که فاقد برچسب طبقه‌اند، وجود دارد. علاوه بر این، بسیاری از روش‌هایی که به منظور گروه‌بندی اشیاء دریایی به کار می‌روند، با در نظر گرفتن ویژگی‌های منفرد (ویژگی‌های حاصل از یک الگوریتم استخراج ویژگی)، به انجام عمل طبقه‌بندی می‌پردازند. به منظور فائق آمدن بر چالش‌های مذکور، در این تحقیق، از رویکرد یادگیری بدون ناظر، استفاده شده، و یک روش خوشه‌بندی اشیاء دریایی، ارائه می‌شود. عمل خوشه‌بندی توسط روش پیشنهادی، با در نظر گرفتن چندین خصوصیت از اعضای مجموعه داده مورد بررسی، صورت می‌پذیرد، تا قابلیت وفق‌پذیری روش مذکور، با کاربردهای مختلف و متفاوت، افزایش پیدا کند. از طرف دیگر، با توجه به نقاط قوت استفاده از ساختار گراف در روش پیشنهادی، و با توجه به این‌که بر اساس بررسی‌های انجام شده، استفاده از مباحث مرتبط با تحلیل شبکه‌های اجتماعی به منظور گروه‌بندی اشیاء دریایی، در ادبیات موضوع، سابقه ندارد، عمل خوشه‌بندی اشیاء دریایی در روش پیشنهادی، با به‌کارگیری مباحث مرتبط با حوزه تشخیص اجتماع در شبکه‌های اجتماعی، که ناظر به عمل خوشه‌بندی بر روی گراف‌ها هستند، صورت می‌پذیرد.

#### ۴- روش پیشنهادی

کلیات روش پیشنهادی، در شکل (۲) نشان داده شده است. روش پیشنهادی، طی ۴ مرحله تولید ویژگی، ایجاد ماتریس‌های شباهت، ایجاد ماتریس شباهت کل و تشخیص اجتماع، عمل می‌کند. در ادامه این بخش، مراحل مختلف روش پیشنهادی، به تفصیل مورد بررسی قرار می‌گیرند.

##### ۴-۱- مرحله اول: تولید ویژگی

همان‌طور که پیش‌تر اشاره شد، روش پیشنهادی تحقیق حاضر، یک روش خوشه‌بندی اشیاء دریایی می‌باشد. لذا، به‌کارگیری چنین روشی، مستلزم وجود یک مجموعه داده، که حاوی فایل‌های صوتی مرتبط با اشیاء



شکل (۲): روش پیشنهادی تحقیق حاضر

الگوریتم‌های تولید ویژگی می‌باشند، به منابع اشاره شده برای آن‌ها در لیست بالا، مراجعه شود.

#### ۱-۴-۱- الگوریتم‌های آمارگان سیگنال (SigSta) و آمارگان هیستوگرام سیگنال (SigHisSta)

از آنجایی که یک سیگنال، می‌تواند به لحاظ آماری، ایستا<sup>۹۷</sup> یا غیرایستا باشد، یا این‌که ماهیت تصادفی داشته باشد یا فاقد ماهیت تصادفی باشد، می‌توان از این سیگنال، تبدیل‌های مختلفی استخراج کرد. روش آمارگان<sup>۹۸</sup> سیگنال و روش آمارگان هیستوگرام سیگنال، دو نمونه از این تبدیل‌ها می‌باشند. روش آمارگان سیگنال، سیگنال خام را دریافت کرده، آن را وارد فرایند آماری می‌کند، و آمارگان را بر روی خود سیگنال، محاسبه می‌کند. در این روش، میانگین، واریانس، انحراف معیار، چولگی<sup>۹۹</sup>، کشیدگی<sup>۱۰۰</sup> و آنتروپی مربوط به سیگنال موردنظر، محاسبه شده، و این آمارگان، در کنار هم چیده شده، و به عنوان ویژگی، در نظر گرفته می‌شوند. از طرف دیگر، روش آمارگان هیستوگرام سیگنال نیز سیگنال خام را دریافت می‌کند، منتها در این روش، هیستوگرام سیگنال مذکور، محاسبه شده، این هیستوگرام وارد فرایند آماری شده، و آمارگان بر روی این هیستوگرام، محاسبه می‌شوند. در این روش، میانگین، واریانس، انحراف معیار، چولگی، کشیدگی و آنتروپی مربوط به هیستوگرام سیگنال موردنظر، محاسبه شده، و این آمارگان، در کنار هم چیده شده، و به عنوان ویژگی، در نظر گرفته می‌شوند.

پایان مرحله اول، ۱۶ مجموعه مختلف که هر یک، شامل  $n$  مجموعه از ویژگی‌ها می‌باشند، آماده خواهند شد.

به طور کلی، روش‌های تحلیل سیگنال را می‌توان در ۳ گروه روش‌های مرتبط با حوزه زمان، روش‌های مرتبط با حوزه فرکانس، تقسیم‌بندی کرد. از میان الگوریتم‌های تولید ویژگی که در مرحله اول روش پیشنهادی، مورد استفاده قرار می‌گیرند، الگوریتم‌های تحلیل پوش (Envelope Analysis)، کدگذاری پیش‌بین خطی (LPC)، آمارگان سیگنال (SigSta) و آمارگان هیستوگرام سیگنال (SigHisSta)، در گروه اول (روش‌های مرتبط با حوزه زمان)، الگوریتم‌های ضرایب کپسترال فرکانس مل (FRQWIDE)، (MFCC)، تبدیل کسینوسی گسسته (DCT)، تحلیل مولفه اصلی (PCA)، آمارگان طیفی (SpecSta)، آمارگان هیستوگرام طیفی (SpecHisSta)، طیفی (Spectral)، چندکاهنده (Multitaper) و بانک فیلتر (Filter Bank)، در گروه دوم (روش‌های مرتبط با حوزه فرکانس)، و الگوریتم‌های تحلیل کپستروم (Cepstrum Analysis)، تبدیل موجک (WT) و فیلتر شکافی (Notch Filter)، در گروه سوم (روش‌های مرتبط با حوزه زمان-فرکانس)، تقسیم‌بندی می‌شوند.

در ادامه این زیربخش، به بررسی الگوریتم‌های تولید ویژگی آمارگان سیگنال (SigSta)، آمارگان هیستوگرام سیگنال (SigHisSta)، FRQWIDE، آمارگان طیفی (SpecSta)، آمارگان هیستوگرام طیفی (SpecHisSta) و طیفی (Spectral)، پرداخته می‌شود. برای کسب اطلاعات بیشتر راجع به سایر الگوریتم‌ها، که از معروف‌ترین

## ۲-۱-۴- الگوریتم FRQWIDE

مبنای روش FRQWIDE، تقسیم طیف فرکانسی سیگنال ورودی، به نواحی مجزا، و محاسبه توان طیفی در هر یک از این نواحی، به عنوان عنصر بردار ویژگی، می باشد. در روش FRQWIDE، می توان در پنجره گذاری ها، توجه به باندهای پایین تر و باندهای بالاتر را مدیریت کرد. مثلا می توان تعداد گام های بیشتری را در فرکانس های پایین، نسبت به باندهای بالاتر صوتی، در نظر گرفت. از آنجایی که در بسیاری از سیگنال های دریافتی (به خصوص سیگنال های دریافتی از کشتی ها)، اطلاعات به طور یکنواخت در طیف سیگنال صوتی قرار ندارند، بلکه در فرکانس های پایین، میزان به مراتب بیشتری از اطلاعات نسبت به باندهای بالاتر صوتی قرار دارند، از این رو، به منظور یکنواخت کردن میزان اطلاعات عناصر بردار ویژگی، انتخاب بهینه این است که تقسیم طیف فرکانسی در باندهای پایین، با فشردگی بیشتری نسبت به فرکانس های باندهای بالاتر صورت پذیرد. در چنین شرایطی، استفاده از روش FRQWIDE می تواند گزینه مناسبی باشد.

## ۳-۱-۴- الگوریتم های آمارگان طیفی (SpecSta) و آمارگان هیستوگرام طیفی (SpecHisSta)

از آنجایی که طیف فرکانسی یک سیگنال، می تواند به لحاظ آماری، ایستا یا غیرایستا باشد، یا این که ماهیت تصادفی داشته باشد یا فاقد ماهیت تصادفی باشد، می توان از این طیف فرکانسی نیز تبدیل های مختلفی استخراج کرد. روش آمارگان طیفی و روش آمارگان هیستوگرام طیفی، دو نمونه از این تبدیل ها می باشند. روش آمارگان طیفی، سیگنال خام را دریافت کرده، طیف فرکانسی آن را محاسبه کرده (در واقع با این کار، سیگنال از حوزه زمان به حوزه فرکانس منتقل می شود)، آن طیف را وارد فرایند آماری می کند، و آمارگان را بر روی خود طیف، محاسبه می کند. در این روش، میانگین، واریانس، انحراف معیار، چولگی، کشیدگی و آنتروپی مربوط به طیف سیگنال مورد نظر، محاسبه شده، و این آمارگان، در کنار هم چیده

شده، و به عنوان ویژگی، در نظر گرفته می شوند. از طرف دیگر، روش آمارگان هیستوگرام طیفی نیز سیگنال خام را دریافت کرده، و طیف فرکانسی آن را محاسبه می کند، منتها در این روش، هیستوگرام طیف حاصل، محاسبه شده، هیستوگرام مذکور وارد فرایند آماری شده، و آمارگان بر روی این هیستوگرام، محاسبه می شوند. در این روش، میانگین، واریانس، انحراف معیار، چولگی، کشیدگی و آنتروپی مربوط به هیستوگرام طیف سیگنال مورد نظر، محاسبه شده، و این آمارگان، در کنار هم چیده شده، و به عنوان ویژگی، در نظر گرفته می شوند.

## ۴-۱-۴- الگوریتم طیفی (Spectral)

در روش طیفی، سعی می شود که به کمک ریاضیات مربوط به حوزه سیگنال، یک سیگنال را تا جایی که امکان دارد، کمی کرد (به یک حوزه کمی وارد کرد). بنابراین، در روش مذکور، با استخراج اطلاعاتی مانند رُل آف طیفی<sup>۱۰۱</sup>، مرکز طیفی<sup>۱۰۲</sup>، پهنای باند سیگنال و نسبت انرژی باند<sup>۱۰۳</sup>، از روی طیف مربوط به سیگنال مورد نظر، و قرار دادن اطلاعات مذکور در کنار هم، ویژگی سیگنال مربوطه، تولید می شود.

## ۳-۴- مرحله دوم: ایجاد ماتریس های شباهت

در مرحله دوم روش پیشنهادی، به ازای نتایج حاصل از هر الگوریتم تولید ویژگی (که در مرحله اول به دست آمدند)، یک ماتریس شباهت ساخته می شود. در ادامه این زیربخش، نحوه ساخت این ماتریس های شباهت، با ذکر یک مثال توضیح داده می شود.

فرض کنید که مجموعه داده ای که برای پردازش توسط روش پیشنهادی در نظر گرفته شده است، حاوی ۳۰ عضو باشد. همان طور که پیش تر اشاره شد، در مرحله اول، هر یک از ۱۶ الگوریتم تولید ویژگی روش پیشنهادی، مجموعه ای از ویژگی ها را به ازای هر یک از ۳۰ عضو مجموعه داده مذکور، ایجاد می کنند. در مرحله دوم،

101-Spectral roll-off

102-Spectral centroid

103-Band energy ratio

تابع  $\text{corr2}$  برای دو مجموعه ویژگی  $M$  ستونه، که یکی شامل  $K$  سطر داده و دیگری شامل  $L$  سطر داده باشد (به شرطی که  $K < L$  باشد)، بایستی تنها  $L$  سطر اول مجموعه  $K$  سطری را در نظر گرفت.

لازم به ذکر است که برای درایه‌های قطر اصلی ماتریس‌های شباهتی که در این مرحله ساخته می‌شوند، مقدار صفر در نظر گرفته می‌شود، چرا که مقادیر موجود بر روی قطر اصلی، تاثیری در محاسبات مراحل بعد روش پیشنهادی، نخواهند داشت. بدیهی است که ماتریس شباهت مربوط به نتایج یک الگوریتم تولید ویژگی، متقارن می‌باشد، و می‌توان آن را به عنوان یک ماتریس مجاورت، برای ایجاد گراف نتایج آن الگوریتم تولید ویژگی، در نظر گرفت.

به عنوان یک جمع‌بندی از مطالب ذکر شده در مرحله دوم روش پیشنهادی، می‌توان گفت که خروجی این مرحله ساخت یک ماتریس شباهت  $n \times n$  (که  $n$ ، تعداد اعضای موجود در مجموعه داده‌ای می‌باشد، که برای پردازش توسط روش پیشنهادی، در نظر گرفته شده است) برای نتایج حاصل از هر یک از الگوریتم‌های شانزده‌گانه تولید ویژگی (که در مرحله اول روش پیشنهادی، به دست آمدند) می‌باشد، که در نتیجه، در انتهای مرحله دوم روش پیشنهادی، ۱۶ ماتریس شباهت، تولید خواهند شد.

### ۳-۴- مرحله سوم: ایجاد ماتریس شباهت کل

در این مرحله، یک ماتریس شباهت کل، با تجميع ماتریس‌های شباهت شانزده‌گانه ایجاد شده در مرحله دوم، ساخته می‌شود. در ادامه، نحوه ساخت این ماتریس شباهت کل، با ذکر یک مثال، توضیح داده می‌شود.

فرض کنید که برای یک مجموعه داده، که شامل داده‌های صوتی مربوط به ۳۰ شیء می‌باشد، ۱۶ ماتریس شباهت ۳۰ در ۳۰، به ازای نتایج حاصل از الگوریتم‌های شانزده‌گانه تولید ویژگی در مرحله دوم، ساخته شده باشند. در مرحله سوم روش پیشنهادی، به سادگی، با

شباهت دو به دوی مجموعه‌های ویژگی تولید شده توسط هر الگوریتم تولید ویژگی، با به‌کارگیری یک معیار شباهت، اندازه‌گیری می‌شود، و نتایج، در یک ماتریس شباهت ۳۰ در ۳۰ (متناظر با تعداد اعضای موجود در مجموعه داده)، ذخیره خواهند شد. مثلاً، شباهت بین ویژگی‌های تولید شده توسط الگوریتم MFCC برای اعضای ۱ و ۲، در درایه ۱ و ۲ (و متقارن با آن، در درایه ۲ و ۱) ماتریس شباهت مربوط به نتایج الگوریتم MFCC، قرار خواهد گرفت. در روش پیشنهادی، شباهت بین دو مجموعه ویژگی، با محاسبه ضریب هم‌بستگی دو-بعدی [۷۲]، اندازه گرفته می‌شود.

تحلیل هم‌بستگی دو-بعدی، یک روش ریاضیاتی می‌باشد، که به منظور بررسی تغییرات در سیگنال‌های اندازه‌گیری شده، به کار می‌رود. همان‌طور که پیش‌تر اشاره شد، در روش پیشنهادی، به منظور اندازه‌گیری شباهت میان دو عضو یک مجموعه داده (یا به عبارت دیگر، شباهت میان ویژگی‌های تولید شده برای دو عضو یک مجموعه داده)، از ضریب هم‌بستگی دو-بعدی استفاده می‌شود. ضریب هم‌بستگی دو-بعدی برای دو ماتریس  $A$  و  $B$ ، به صورت زیر محاسبه می‌شود [۷۲]:

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{\sum_m \sum_n (A_{mn} - \bar{A})^2 \sum_m \sum_n (B_{mn} - \bar{B})^2}}$$

که در آن،  $\bar{A}$  و  $\bar{B}$ ، به ترتیب، میانگین کل داده‌های موجود در ماتریس  $A$  و  $B$  می‌باشند [۷۲]. این مقدار را می‌توان با فراخوانی تابع  $\text{corr}^2$  در زبان برنامه‌نویسی متلب<sup>۱۰۰</sup>، محاسبه کرد. از آنجایی که ورودیهای تابع  $\text{corr}^2$ ، ماتریس‌های هم‌اندازه می‌باشند، لذا بایستی هر دو مجموعه ویژگی که به عنوان ورودی به این تابع داده می‌شوند، با یکدیگر هم‌اندازه شوند. تعداد ستون‌های ویژگی‌های تولید شده برای هر عضو موجود در مجموعه داده، به ازای یک الگوریتم تولید ویژگی، با یکدیگر برابر بوده، و تفاوت احتمالی، فقط در تعداد سطرها می‌باشد. لذا، برای محاسبه

شباهت بین اعضای ۱۰ و ۱۲ مجموعه داده مورد پردازش توسط روش پیشنهادی را نشان می‌دهد. بنابراین، چنین ماتریسی به راحتی می‌تواند به عنوان ماتریس مجاورت یک گراف وزن دار، در نظر گرفته شود، به طوری که هر یک از اعضای موجود در مجموعه داده، یک گره از این گراف، و مقدار موجود در هر درایه از ماتریس شباهت کل، وزن مربوط به یال بین گره‌های متناظر با آن درایه را در این گراف، مشخص کنند. با به دست آوردن گراف ماتریس شباهت کل ساخته شده در مرحله سوم، بایستی هدف نهایی، که همان به دست آوردن اجتماعات اعضای موجود در مجموعه داده مورد پردازش می‌باشد، محقق شود. برای این کار، ۳ الگوریتم لیست زیر، بر روی گراف مربوط به ماتریس شباهت مرحله سوم، اعمال می‌شوند:

• الگوریتم ModulMax1 [۷۳]

• الگوریتم LFK [۷۴]

• الگوریتم SpectralClust1 [۷۵]

سه الگوریتم لیست بالا، که در ادامه، به توضیح آن‌ها خواهیم پرداخت، الگوریتم‌های تشخیص اجتماع می‌باشند، که استراتژی‌های مختلف و متنوعی را برای انجام عمل تشخیص اجتماع، در نظر می‌گیرند. در واقع، الگوریتم ModulMax1، به بیشینه‌سازی تابع پیمانی می‌پردازد. الگوریتم LFK، یک روش تشخیص اجتماع چندتفکیکی<sup>۱۰۶</sup> می‌باشد. تفکیک یا مقیاس<sup>۱۰۷</sup>، به سطح جزئیاتی اشاره می‌کند که با توجه به آن، تحلیل‌ها می‌توانند به منظور کشف یک ساختار مرتبط بالقوه در یک شبکه، انجام شوند [۷۶]، چرا که شبکه‌ها، عموماً از سطوح ساختار مختلفی برخوردارند [۷۷]، که این سطوح ساختار، منجر به حضور اجتماعات مرتبط متفاوتی در مقیاس‌های مختلف، خواهند شد [۷۶]. الگوریتم SpectralClust1 نیز از مفاهیم مربوط به خوشه‌بندی طیفی [۶]، در عمل تشخیص اجتماع استفاده می‌کند. با به کارگیری الگوریتم‌های ذکر شده، می‌توان تا حدود زیادی مطمئن بود که نتایج کاملی از عمل تشخیص

جمع مقادیر درایه‌های نظیر به نظیر هر یک از ماتریس‌های شباهت ساخته شده در مرحله دوم، یک ماتریس شباهت کل، حاصل می‌شود.

برای ذکر چرایی تشکیل ماتریس شباهت کل، می‌توان گفت که از آنجایی که هر یک از الگوریتم‌های تولید ویژگی شانزده‌گانه روش پیشنهادی، احتمالاً از یک منظر و جنبه خاص و منحصر به فردی، به تولید ویژگی یک مجموعه داده می‌پردازند، لذا با تجميع ماتریس‌های شباهت حاصل از نتایج الگوریتم‌های تولید ویژگی مذکور، شاید بتوان نقاط قوت هر یک از الگوریتم‌های مذکور را در نتایج کار، دخیل کرد. بدیهی است که ماتریس شباهت کل، یک ماتریس متقارن هم‌اندازه با هر یک از ماتریس‌های شباهتی که در مرحله دوم روش پیشنهادی ساخته شدند، می‌باشد به عنوان یک جمع‌بندی از مطالب ذکر شده در مرحله سوم روش پیشنهادی، می‌توان گفت که خروجی این مرحله، ساخت یک ماتریس شباهت کل  $n \times n$  (که  $n$ ، تعداد اعضای موجود در مجموعه داده‌ای می‌باشد، که برای پردازش توسط روش پیشنهادی، در نظر گرفته شده است) می‌باشد، که می‌توان این ماتریس شباهت را به عنوان یک ماتریس مجاورت برای ایجاد گراف حاصل از کلیه نتایج الگوریتم‌های تولید ویژگی شانزده‌گانه روش پیشنهادی، در نظر گرفت.

#### ۴-۴- مرحله چهارم: تشخیص اجتماع

در آخرین مرحله، به استخراج اجتماعات از گراف مربوط به ماتریس شباهت کل ساخته شده در مرحله سوم، پرداخته می‌شود. همان‌طور که پیش‌تر اشاره شد، ماتریس شباهت ساخته شده در مرحله سوم، یک ماتریس متقارن بوده، که مقادیر روی قطر اصلی آن، برابر صفر می‌باشند، و مقدار مربوط به هر درایه، نشان‌دهنده میزان شباهت کل اندازه‌گیری شده (توسط ضریب هم‌بستگی دو-بعدی) بین اعضای مربوط به آن درایه، می‌باشد. مثلاً مقدار درایه مربوط به سطر ۱۰ و ستون ۱۲ ماتریس شباهت کل، میزان

شد، و الگوریتم متوقف می‌شود [۶].

### ۳-۴-۴ الگوریتم LFK

لانسچیپنتی و همکاران [۷۴]، یک الگوریتم چندتفکیکی (الگوریتم LFK) ارائه کردند، که به طور هم‌زمان، قادر به شناسایی ساختار سلسله‌مراتبی یک گراف و اجتماعات هم‌پوشان در آن گراف، می‌باشد. این الگوریتم، بر اساس بهینه‌سازی یک تابع برازش عمل می‌کند، که این تابع، قدرت یک خوشه را تخمین می‌زند، و مستلزم دانستن یک پارامتر تفکیک به نام  $\alpha$  می‌باشد. در اصل، تابع برازش مذکور، می‌تواند دلخواه باشد، اما لانسچیپنتی و همکاران، برای کاربرد موردنظرشان، یک حدس ریاضیاتی ساده را بر اساس تناسب<sup>۱۱۲</sup> بین درجه داخلی و درجه کل خوشه مربوطه، انتخاب کردند. فرایند بهینه‌سازی در الگوریتم LFK، با یک خوشه که شامل یک گره دلخواه می‌باشد، آغاز می‌شود. با توجه به یک مرکز خوشه، تا زمانی که مقدار تابع برازش، افزایش پیدا کند، گره‌های همسایه به خوشه مربوطه اضافه شده یا از آن کم می‌شوند. مقدار تابع برازش، پس از هر اضافه یا کم شدن یک گره، مجدداً محاسبه می‌شود. در جایی، بیشینه محلی، حاصل می‌شود، و خوشه مربوطه، بسته خواهد شد. سپس، از میان گره‌هایی که هنوز به خوشه‌ای اختصاص داده نشده‌اند، گرهی به تصادف انتخاب شده، یک خوشه جدید ایجاد شده، و فرایند مذکور تا جایی که تمامی گره‌های گراف موردنظر به خوشه‌ها اختصاص یابند، ادامه پیدا می‌کند. در مدت‌زمان ساخت یک خوشه، گره‌هایی که به خوشه‌های دیگر نسبت داده شده باشند نیز ممکن است شامل خوشه در حال ساخت گردند. بنابراین می‌توان گفت که در الگوریتم LFK، اجتماعات یافت شده می‌توانند هم‌پوشان باشند. در الگوریتم LFK، افرازهای مناسب، به وسیله خوشه‌هایی که در هیستوگرام مقادیر تابع برازش برای پوشش‌ها<sup>۱۱۳</sup> (که این هیستوگرام مقادیر تابع برازش برای پوشش‌ها، به ازای مقادیر مختلف  $\alpha$ ، به دست

اجتماع، با در نظر گرفتن جنبه‌های مختلف، حاصل خواهند شد. در واقع، خروجی روش پیشنهادی، افرازهای مختلفی از مجموعه داده مورد پردازش خواهند بود، که توسط الگوریتم‌های مختلف تشخیص اجتماع، حاصل می‌شوند.

### ۱-۴-۴ الگوریتم ModulMax1

الگوریتم ModulMax1، یک رویکرد حریصانه<sup>۱۱۸</sup> می‌باشد، که توسط بلاندل و همکاران [۷۳]، در حالت کلی برای گراف‌های وزن‌دار، ارائه شد. در این الگوریتم، در ابتدا، تمامی گره‌های گراف، در اجتماعات مجزا قرار داده می‌شوند. مرحله اول، شامل یک رفت و برگشت پی‌درپی روی تمامی گره‌ها می‌باشد. اگر گره  $i$  داده شود، با قرار دادن گره  $i$  در اجتماع مربوط به همسایه  $i$  این گره، میزان افزایش در مقدار پیمانی وزن‌دار (رابطه ۲)، محاسبه شده، و گره  $i$ ، در اجتماعی از همسایگانش قرار خواهد گرفت، که موجب بیشترین افزایش، (البته تا زمانی که این افزایش مثبت باشد) در مقدار پیمانی وزن‌دار بشود. در انتهای فرایند رفت و برگشت، افراز سطح اول<sup>۱۱۹</sup> حاصل خواهد شد. در مرحله دوم، اجتماعات با ابرگره‌ها<sup>۱۲۰</sup> جایگزین می‌شوند. دو ابرگره، به هم متصل خواهند بود، اگر حداقل یک یال بین گره‌های اجتماعات مرتبطشان، وجود داشته باشد. در این حالت، وزن یال بین ابرگره‌ها، برابر مجموع وزن‌های یال‌های بین اجتماعات مرتبطشان، که در سطح پایین‌تر حاصل شدند، خواهد بود. سپس، دو مرحله الگوریتم که تا این‌جا گفته شد، مجدداً تکرار می‌شوند، تا سطوح سلسله‌مراتبی و ابرگراف‌ها حاصل شوند. لازم به ذکر است که مقدار پیمانی، همواره بر اساس ساختار همبندی<sup>۱۲۱</sup> گراف اولیه، محاسبه می‌شود. پردازش ابرگراف‌ها، شخص را قادر می‌سازد، تا تغییرات مقدار پیمانی را، پس از ادغام و یا جداسازی گروه‌های گره‌ها، برای افرازهای گراف اولیه، در نظر بگیرد. بنابراین، در بعضی تکرارهای الگوریتم، مقدار پیمانی، بیشتر نخواهد

108-Greedy approach

109-First level partition

110-Supervertices

111-Topological structure

112-Trade-off

113-Covers

می‌باشند، یعنی خوشه (اجتماع) مربوط به هر عضو این مجموعه داده‌ها، کاملاً مشخص شده‌اند. با کمک دو مجموعه داده مذکور، می‌توان نتایج حاصل از روش پیشنهادی را، با میزان درستی بالایی ارزیابی کرد. اطلاعات مربوط به این مجموعه داده‌ها، در جدول (۱) قرار داده شده‌اند.

## ۲-۵- معیار ارزیابی: شاخص ژاکارد

گرافی مانند  $G$  را در نظر بگیرید. فرض کنید که افراز  $X = (X_1, X_2, \dots, X_{n_X})$  (با  $n_X$  تعداد اجتماع) از گراف  $G$ ، شامل اجتماعات واقعی گراف مذکور باشد، و افراز  $Y = (Y_1, Y_2, \dots, Y_{n_Y})$  (با  $n_Y$  تعداد اجتماع) از گراف  $G$ ، افرازی باشد که با اعمال یک الگوریتم تشخیص اجتماع به گراف مذکور، حاصل شده باشد. برای اندازه‌گیری میزان تشابه دو افراز مذکور با استفاده از شاخص ژاکارد، از رابطه زیر استفاده می‌شود [۶]:

$$(X, Y) = \frac{a_{11}}{a_{11} + a_{12} + a_{21}}$$

که  $a_{11}$ ، تعداد جفت گره‌هایی که در هر دو افراز  $X$  و  $Y$  در اجتماعی مشابه حضور دارند را نشان می‌دهد.  $a_{12}$ ، تعداد جفت گره‌هایی که در افراز  $X$ ، در اجتماعی مشابه، و در افراز  $Y$ ، در اجتماعات متفاوتی حضور دارند را نشان می‌دهد. و  $a_{21}$ ، تعداد جفت گره‌هایی که در افراز  $Y$ ، در اجتماعی مشابه، و در افراز  $X$ ، در اجتماعات متفاوتی حضور دارند را نشان می‌دهد.

در واقع، شاخص ژاکارد، که شباهت میان دو افراز را نشان می‌دهد، برابر نسبت تعداد جفت گره‌هایی که در هر دو افراز به یک اجتماع نسبت داده شده‌اند، به جفت گره‌هایی که در حداقل یک افراز به اجتماعات مشابهی نسبت داده شده‌اند، می‌باشد [۶]. بیشترین مقدار شاخص ژاکارد، برابر ۱، و کمترین مقدار آن، برابر صفر خواهد بود. به عبارت دیگر، مقدار شاخص ژاکارد همواره در بازه  $[0, 1]$  خواهد بود [۷۹]. بدیهی است که زمانی می‌توان از معیار شاخص ژاکارد برای ارزیابی میزان درستی عملکرد یک الگوریتم تشخیص اجتماع استفاده کرد که مجموعه داده‌ای که برای

می‌آیند) قرار دارند، آشکار می‌شوند. لازم به ذکر است که مقدار تابع برازش برای یک پوشش، برابر میانگین مقادیر تابع برازش مربوط به خوشه‌های آن پوشش، می‌باشد (یک پوشش از یک گراف، تقسیم آن گراف به اجتماعات مختلف است، به طوری که هر گره از گراف، بتواند به چند اجتماع متعلق باشد. در واقع، پوشش، همان افراز می‌باشد، با این تفاوت که در پوشش، اجتماعات می‌توانند هم‌پوشان باشند) [۷۴].

## ۳-۴-۴- الگوریتم SpectralClust1

هسپانها [۷۵]، یک الگوریتم کارآمد تشخیص اجتماع (الگوریتم SpectralClust1)، با کمک خوشه‌بندی طیفی، ارائه داده، و آن را با زبان برنامه‌نویسی متلب، پیاده‌سازی کرده است. الگوریتم مذکور، که یک الگوریتم افرازبندی گراف می‌باشد، سعی می‌کند که کل هزینه یال‌های قطع شده<sup>۱۱۴</sup> را با خوشه‌بندی بردارهای ویژه<sup>۱۱۵</sup> یک اصلاح (تصادفی مضاعف<sup>۱۱۶</sup>) از ماتریس یال-هزینه<sup>۱۱۷</sup>، حول  $x \in V$  بردار ویژه‌ای که از همه به صورت خطی مستقل‌تر است، کاهش دهد [۷۸].

## ۵- آزمایش و تحلیل نتایج

در این بخش، به شرح آزمایشی که به منظور ارزیابی عملکرد روش پیشنهادی بر روی دو مجموعه داده، انجام شده است، می‌پردازیم، و نتایج این آزمایش، ارائه می‌شوند. در این راستا، دو مجموعه داده مذکور، معرفی شده، و سپس، شاخص ژاکارد، بررسی می‌شود. پس از آن، تنظیمات صورت پذیرفته در انجام آزمایش تحقیق، مطرح می‌شوند. در نهایت، آزمایش انجام شده در تحقیق، به طور مبسوط، تشریح و بررسی می‌شود.

## ۱-۵- مجموعه داده‌ها

هر یک از دو مجموعه داده مورد استفاده، برچسب‌دار

- 114-Cut edges
- 115-Eigenvectors
- 116-Doubly stochastic
- 117-Edge-cost matrix

بررسی در نظر گرفته شد.

لازم به ذکر است که در این تحقیق، برای الگوریتم‌های LFK، ModulMax1 و SpectralClust1، و برای معیار ارزیابی شاخص ژاکارد معرفی شده در زیربخش ۵-۲، از کدهای مربوطه در جعبه‌ابزار تشخیص اجتماع (CDTB)<sup>۱۱۸</sup> نوشته شده برای نرم‌افزار متلب [۷۹]، استفاده شد. نتایج تجربی برای تمامی الگوریتم‌های تشخیص اجتماع مورد استفاده در روش پیشنهادی، با در نظر گرفتن بهترین عملکرد از بین نتایج ۱۰ اجرای مستقل هر یک از این الگوریتم‌ها، بر روی دو مجموعه داده معرفی شده در زیربخش ۵-۱، گزارش شده‌اند.

#### ۴-۵- شرح آزمایش تحقیق و بررسی نتایج آن

مراحل اول، سوم و چهارم روش پیشنهادی، دقیقاً به همان صورتی که در بخش چهارم شرح داده شدند، اجرا شدند، اما در انجام مرحله دوم روش پیشنهادی (مرحله ایجاد ماتریس‌های شباهت)، این مورد در نظر گرفته شد که تمام مقادیر شباهت‌های کمتر از صفر بین هر دو عضو یک مجموعه داده، که با اعمال معیار هم‌بستگی بر روی نتایج هر الگوریتم تولید ویژگی، به دست می‌آیند، به مقدار صفر تبدیل شوند، چرا که روش پیشنهادی، در ساختار فعلی خود، شباهت منفی و عدم شباهت (شباهت صفر) را یکسان فرض می‌کند. بدیهی است که در این حالت، ماتریس شباهت کلی، که در مرحله سوم حاصل خواهد شد، حاوی مقادیر منفی نخواهد بود. پس از شرح آزمایش تحقیق، در ادامه، به بررسی نتایج حاصل از انجام این آزمایش بر روی مجموعه داده‌های شرح داده شده، پرداخته می‌شود.

در مرحله اول، هر یک از الگوریتم‌های تولید ویژگی (معرفی شده در زیربخش ۴-۱)، به عمل تولید ویژگی برای هر یک از اعضای موجود در مجموعه داده‌ها، پرداختند. خروجی این مرحله، برای مجموعه داده اول، ۱۶ مجموعه (به ازای هر الگوریتم تولید ویژگی) بود، که هر یک، خود

جدول (۱): مجموعه داده‌های مورد استفاده


| مجموعه داده دوم |           | مجموعه داده اول |           |
|-----------------|-----------|-----------------|-----------|
| شماره خوشه      | شماره شیء | شماره خوشه      | شماره شیء |
| ۱               | ۱         | ۱               | ۱         |
| ۲               | ۲         |                 | ۲         |
|                 | ۳         |                 | ۳         |
| ۳               | ۴         | ۲               | ۴         |
|                 | ۵         |                 | ۵         |
|                 | ۶         |                 | ۶         |
| ۴               | ۷         | ۳               | ۷         |
|                 | ۸         | ۴               | ۸         |
|                 | ۹         |                 | ۹         |
|                 | ۱۰        | ۵               | ۱۰        |
| ۵               | ۱۱        |                 | ۱۱        |
|                 | ۱۲        | ۶               | ۱۲        |
|                 | ۱۳        |                 | ۱۳        |
|                 | ۱۴        |                 | ۱۴        |
| ۶               | ۱۵        | ۷               | ۱۵        |
|                 | ۱۶        | ۸               | ۱۶        |
|                 | -         |                 | -         |
| -               | -         | ۱۷              | -         |

بررسی عملکرد آن الگوریتم استفاده می‌شود، حاوی اجتماعات محک باشد (یعنی، اجتماعات واقعی در مجموعه داده مذکور، مشخص باشند).


#### ۳-۵- پارامترهای تنظیم شده

کلیت روش پیشنهادی، به همراه آزمایش طراحی شده، در نرم‌افزار متلب و بر روی رایانه‌ای با مشخصات Intel Core 2 Duo 2.20GHz CPU, 2 GB RAM پیاده‌سازی شده‌اند. تنظیمات صورت پذیرفته در روش پیشنهادی، به شرح زیر می‌باشند:

- برای تمامی الگوریتم‌های تولید ویژگی، پارامتر *ovrlp* (میزان هم‌پوشانی) برابر با ۰/۲۵ در نظر گرفته شد.
- برای الگوریتم LFK، مقدار پارامتر *Scale* (مقیاس) از ۱ تا ۴، با فواصل ۱، ۰ در نظر گرفته شد.
- برای الگوریتم SpectralClust1، مقدار پارامتر *Kmax* (تعداد بیشینه خوشه‌ها) برابر با تعداد گره‌های شبکه مورد



شکل (۳): شبکه مربوط به مجموعه داده اول



شکل (۴): شبکه مربوط به مجموعه داده دوم

اجتماع را در یافتن اجتماعات مربوط به مجموعه داده‌های اول و دوم، نشان می‌دهند. عملکرد هر یک از الگوریتم‌ها، با معیار شاخص ژاکارد معرفی شده در زیربخش ۵-۲، ارزیابی شدند. بهترین نتایج به دست آمده به ازای این معیار ارزیابی، به صورت توپر، در جدول‌های مذکور، نشان داده شده‌اند.

جدول (۲): نتایج مرحله چهارم روش پیشنهادی (با در نظر گرفتن مجموعه داده اول) - نتایج عملکرد ۳ الگوریتم تشخیص اجتماع بر روی شبکه شکل (۳)

| Algorithm | Jaccard Index |
|-----------|---------------|
|-----------|---------------|

شامل ۱۷ مجموعه از ویژگی‌ها (به ازای هر عضو مجموعه داده اول) بودند، و برای مجموعه داده دوم، ۱۶ مجموعه بود، که هر یک، خود شامل ۱۶ مجموعه از ویژگی‌ها (به ازای هر عضو مجموعه داده دوم) بودند.


در مرحله دوم، برای هر مجموعه داده، به ازای نتایج حاصل از هر الگوریتم تولید ویژگی، یک ماتریس شباهت، ساخته شد. بنابراین، در این مرحله، برای هر یک از مجموعه داده‌ها، ۱۶ ماتریس شباهت، حاصل شدند، که البته برای مجموعه داده اول، این ماتریس‌ها، ۱۷ در ۱۷ بودند (چرا که مجموعه داده اول، ۱۷ عضو دارد)، و برای مجموعه داده دوم، این ماتریس‌ها، ۱۶ در ۱۶ بودند (چرا که مجموعه داده دوم، ۱۶ عضو دارد).

در مرحله سوم، به ازای هر مجموعه داده، یک ماتریس شباهت کل، با در نظر گرفتن نتایج مرحله قبل، ساخته شد. در واقع، برای مجموعه داده اول، یک ماتریس شباهت کل ۱۷ در ۱۷، و برای مجموعه داده دوم، یک ماتریس شباهت کل ۱۶ در ۱۶، با تجميع اطلاعات ماتریس‌های شباهت ساخته شده در مرحله قبل (به ازای هر یک از مجموعه داده‌ها)، به دست آمدند. هر یک از این ماتریس‌های شباهت، به عنوان یک ماتریس مجاورت، برای ایجاد شبکه (گراف) حاصل از کلیه نتایج الگوریتم‌های تولید ویژگی شانزده‌گانه روش پیشنهادی، به ازای هر یک از مجموعه داده‌ها، در نظر گرفته شدند. شکل (۳)، شبکه به دست آمده برای مجموعه داده اول را نشان می‌دهد، و شکل (۴)، شبکه به دست آمده برای مجموعه داده دوم را نشان می‌دهد. در شبکه‌های مذکور، هر چقدر که وزن یک یال بیشتر باشد، آن یال، پررنگ‌تر است.

در مرحله آخر، به استخراج اجتماعات موجود در شبکه‌های تشکیل شده در مرحله قبل، با اعمال ۳

الگوریتم تشخیص اجتماع معرفی شده در زیربخش ۴-۴ به شبکه‌های مذکور، پرداخته شد. جدول‌های (۲) و (۳)، به ترتیب، نتایج عملکرد هر یک از الگوریتم‌های تشخیص

که الگوریتم LFK موفق شده است که شش مورد از هشت مورد اجتماعات واقعی را به طور کامل شناسایی کند، یعنی خوشه‌های ۱، ۲، ۴، ۵، ۶ و ۸ به طور دقیق توسط الگوریتم، شناسایی شده‌اند. اما الگوریتم LFK، دو خوشه دیگر از مجموعه داده اول، یعنی خوشه‌های ۳ و ۷ (که هر دو، یک اجتماع منفردند، یعنی، هر یک از آن‌ها، تنها، یک عضو دارند) را نتوانست به طور دقیق شناسایی کند، و اعضای این دو خوشه را با هم در یک اجتماع، جای داده است.



شکل (۵): اجتماعات یافت شده در شبکه شکل (۳)، توسط الگوریتم LFK

با جمع‌بندی عملکرد الگوریتم LFK در آزمایش تحقیق، می‌توان این‌طور نتیجه گرفت که این الگوریتم، عملکرد مناسبی را در کشف اجتماعات مربوط به مجموعه داده اول، از خود به نمایش گذاشته است. در واقع، این الگوریتم، توانست به درستی شش اجتماع از بین هشت اجتماع واقعی را شناسایی کند و تنها نکته منفی در عملکرد الگوریتم مذکور، عدم شناسایی درست دو اجتماع منفرد می‌باشد.

#### ۲-۴-۵- بررسی بهترین نتایج تشخیص اجتماع برای مجموعه داده دوم

مطابق با جدول (۳)، برای مجموعه داده دوم، الگوریتم SpectralClust1 بهترین عملکرد را در میان ۳ الگوریتم تشخیص اجتماع، از خود به نمایش گذاشته است، و مقدار شاخص ژاکارد برای این الگوریتم، برابر ۰/۸ بوده است،

|                |       |
|----------------|-------|
| ModulMax1      | 0.188 |
| LFK            | 0.923 |
| SpectralClust1 | 0.625 |

جدول (۳): نتایج مرحله چهارم روش پیشنهادی (با در نظر گرفتن مجموعه داده دوم) - نتایج عملکرد ۳ الگوریتم تشخیص اجتماع بر روی شبکه شکل (۴)

| Algorithm      | Jaccard Index |
|----------------|---------------|
| ModulMax1      | 0.167         |
| LFK            | 0.500         |
| SpectralClust1 | 0.800         |

در ادامه، بهترین نتایج تشخیص اجتماع انجام شده در آزمایش تحقیق، برای مجموعه داده‌های اول و دوم، به تفصیل بررسی می‌شوند.

#### ۱-۴-۵- بررسی بهترین نتایج تشخیص اجتماع برای مجموعه داده اول

مطابق با جدول (۲)، برای مجموعه داده اول، الگوریتم LFK بهترین عملکرد را در میان ۳ الگوریتم تشخیص اجتماع، از خود به نمایش گذاشته است، و مقدار شاخص ژاکارد برای این الگوریتم، برابر ۰/۹۲۳ بوده است، که علاوه بر این‌که بالاترین مقدار به دست آمده در بین رقبا می‌باشد، مقدار بسیار مناسبی برای معیار مذکور به شمار می‌رود. برای بررسی بیشتر عملکرد الگوریتم LFK، بهتر است نگاهی به اجتماعات یافت شده توسط آن بیندازیم، و با بررسی این اجتماعات و مقایسه آن‌ها با اجتماعات واقعی مجموعه داده اول (که در جدول (۱) آمده است)، کیفیت عملکرد این الگوریتم، به طور ملموس‌تری بررسی شود. شکل (۵)، اجتماعات یافت شده توسط الگوریتم LFK را در شبکه شکل (۳)، نشان می‌دهد.

مطابق شکل (۵)، الگوریتم LFK موفق به یافتن هفت اجتماع شده است، که اعضای هر اجتماع، با رنگ مشابه مشخص گردیده‌اند. از بین این هفت اجتماع، چهار اجتماع، ۲ عضوی بوده، و سه اجتماع دیگر، ۳ عضو دارند. با در نظر گرفتن اجتماعات واقعی مجموعه داده اول (مطابق جدول (۱) و اجتماعات تشخیص داده شده در این مجموعه توسط الگوریتم LFK (مطابق شکل ۵)، می‌توان به این مورد پی برد

نتوانست به طور دقیق شناسایی کند، و هر یک از اعضای این خوشه‌ها را در اجتماعات مجزا جای داده است.


با جمع‌بندی عملکرد الگوریتم SpectralClust1، می‌توان این‌طور نتیجه گرفت که این الگوریتم، عملکرد مناسبی را در کشف اجتماعات مربوط به مجموعه داده دوم، از خود به نمایش گذاشته است. در واقع، این الگوریتم، علاوه بر شناسایی درست چهار اجتماع از بین شش اجتماع واقعی، توانست به درستی دو اجتماع منفرد، یعنی خوشه‌های ۱ و ۵، که هر یک، شامل یک عضو می‌باشند، را شناسایی کند، که کار راحتی نمی‌باشد. همچنین، اگرچه این الگوریتم نتوانست به طرز مناسبی اعضای دو خوشه ۲ و ۳ را شناسایی کند، اما اعضای این خوشه‌ها را به خوشه‌های اشتباهی نسبت داد، بلکه هر یک از این اعضا را به عنوان یک خوشه در نظر گرفت، چراکه احتمالاً از نظر الگوریتم، اعضای این خوشه‌ها به حدی با یکدیگر و همچنین با دیگر اعضای شبکه تفاوت داشتند، که می‌بایست در اجتماعات مجزا قرار گیرند.

### ۳-۴-۵- جمع‌بندی نتایج آزمایش انجام شده

اعمال روش پیشنهادی به دو مجموعه داده واقعی این تحقیق (جدول ۱)، منجر به خروجی‌هایی (خوشه‌هایی) شد که این خروجیها با خوشه‌های واقعی هر یک از اعضای این مجموعه داده‌ها، شباهت زیادی داشتند. به منظور اندازه‌گیری این شباهت، همانطور که پیشتر اشاره شد، از شاخص ژاکارد استفاده شد. بنابراین، می‌توان ادعا کرد که با توجه به آزمایش‌های انجام شده در این تحقیق، روشی که در تحقیق حاضر در پیش گرفته شد، به این صورت که عمل تشخیص اجتماع، بر روی شبکه‌ای، که از تجمیع نتایج چندین الگوریتم تولید ویژگی حاصل می‌شود، صورت پذیرد، می‌تواند به نتایج مناسبی، با در نظر گرفتن مقدار شاخص ژاکارد، که شباهت بین خوشه‌های واقعی (خوشه‌های محک) و خوشه‌های خروجی روش پیشنهادی را اندازه‌گیری میکند، برسد.

که علاوه بر این که بالاترین مقدار به دست آمده در بین رقبا می‌باشد، مقدار بسیار مناسبی برای معیار مذکور به شمار می‌رود.

برای بررسی بیشتر این الگوریتم، بهتر است که نگاهی به اجتماعات یافت شده توسط آن انداخته شود. شکل (۶)، اجتماعات یافت شده توسط الگوریتم SpectralClust1 را در شبکه شکل (۴)، که مربوط به مجموعه داده دوم می‌باشد، نشان می‌دهد. در شکل (۶)، اعضای هر اجتماع، با رنگ مشابه مشخص شده‌اند.



شکل (۶): اجتماعات یافت شده در شبکه شکل (۴)، توسط الگوریتم SpectralClust1


مطابق شکل (۶)، الگوریتم SpectralClust1، موفق به یافتن نه اجتماع شده است. از بین این نه اجتماع، هفت اجتماع، تک عضوی بوده، و دو اجتماع دیگر، یکی ۴ عضو و دیگری ۵ عضو دارند. با در نظر گرفتن اجتماعات واقعی مجموعه داده دوم (مطابق جدول ۱) و اجتماعات تشخیص داده شده در این مجموعه توسط الگوریتم SpectralClust1 (مطابق شکل ۶)، می‌توان به این مورد پی برد که الگوریتم SpectralClust1 موفق شد که چهار مورد از شش مورد اجتماعات واقعی را به طور کامل شناسایی کند، یعنی خوشه‌های ۱، ۴، ۵ و ۶، به طور دقیق توسط الگوریتم، شناسایی شدند. اما الگوریتم SpectralClust1، دو خوشه دیگر از مجموعه داده دوم، یعنی خوشه‌های ۲ و ۳ را

روش پیشنهادی، بر روی دو مجموعه داده حاوی فایل‌های صوتی مربوط به اشیاء دریایی، اعمال شد، و عملکرد آن، با استفاده از معیار شاخص ژاکارد، مورد تحلیل قرار گرفت. نتایج آزمایش انجام شده نشان داد که روشی که در تحقیق حاضر در پیش گرفته شد، به این صورت که عمل تشخیص اجتماع، بر روی شبکه‌ای، که از تجمیع نتایج چندین الگوریتم تولید ویژگی حاصل می‌شود، صورت پذیرد، می‌تواند به نتایج مناسبی، با در نظر گرفتن مقدار شاخص ژاکارد، که شباهت بین خوشه‌های واقعی (خوشه‌های محک) و خوشه‌های خروجی روش پیشنهادی را اندازه‌گیری میکند، برسد. بنابراین، می‌توان ادعا کرد که در صورت وجود یک مجموعه داده مناسب از اشیاء دریایی، روش پیشنهادی می‌تواند به طرز قابل قبولی، مهم‌ترین هدف تحقیق را، که همان رسیدن به یک گروه‌بندی مناسب از اشیاء دریایی می‌باشد، محقق کند. به عنوان نکته آخر، بایستی اشاره کرد که در میان ۳ الگوریتم تشخیص اجتماع به‌کار رفته در روش پیشنهادی، الگوریتم‌های SpectralClust1 و LFK، تقریباً به طور مشترک، بهترین میانگین عملکردها را در آزمایش انجام شده بر روی مجموعه داده‌های اول و دوم تحقیق، به نمایش گذاشتند.

### مراجع

1. Gamage, C., Dinalankara, R., Samarabandu, J. & Subasinghe, A. 2023. "A comprehensive survey on the applications of machine learning techniques on maritime surveillance to detect abnormal maritime vessel behaviors," WMU Journal of Maritime Affairs, vol. 22, no. 4, pp. 447-477.
2. Bishop, C. M. 2006. Pattern recognition and machine learning. springer.
3. Vanem E. & Brandsaeter, A. 2021. "Unsupervised anomaly detection based on clustering methods and sensor data on a marine diesel engine," Journal of Marine Engineering & Technology, vol. 20, no. 4, pp. 217-234.
4. Guo, Z., Qiang, H., Xie, S. & Peng, X. 2024. "Unsupervised knowledge discovery framework: From AIS data processing to maritime traffic networks generating," Applied Ocean Research, vol. 146, p. 103924.
5. Liang, M., Weng, L., Gao, R., Li, Y. & Du, L. 2024. "Unsupervised maritime anomaly detection for intelligent situational awareness using AIS data," Knowledge-Based

از طرف دیگر، مشاهده شد که ۳ الگوریتم تشخیص اجتماع، در مرحله چهارم، مورد استفاده قرار گرفتند. برای بررسی میزان موفقیت الگوریتم‌های تشخیص اجتماع به‌کار رفته در روش پیشنهادی، میانگین نتایج عملکردهای الگوریتم‌های مذکور بر روی مجموعه داده‌های اول و دوم، در آزمایش تحقیق، محاسبه شدند. شکل (۷)، نتایج مذکور را نشان می‌دهد.



شکل (۷): میانگین نتایج عملکردهای ۳ الگوریتم تشخیص اجتماع، بر روی مجموعه داده‌های اول و دوم

با توجه به شکل (۷)، الگوریتم‌های SpectralClust1 و LFK، تقریباً به طور مشترک، بالاترین میانگین‌های شاخص ژاکارد را به خود اختصاص دادند (البته لازم به ذکر است که در واقع، الگوریتم SpectralClust1، با اختلاف بسیار جزئی، بالاترین میانگین شاخص ژاکارد را به خود اختصاص داد). اما الگوریتم ModulMax1، اصلاً عملکرد قابل قبولی در این تحقیق، نداشت.

### ۶- نتیجه‌گیری و کارهای آینده

در این مقاله، از رویکرد یادگیری بدون ناظر استفاده شد، و یک روش خوشه‌بندی اشیاء دریایی، ارائه گردید. روش پیشنهادی، با در نظر گرفتن چندین خصوصیت از اعضای مجموعه داده مورد استفاده، و با به‌کارگیری مباحث مرتبط با حوزه تشخیص اجتماع در شبکه‌های اجتماعی، که ناظر به عمل خوشه‌بندی بر روی گراف‌ها هستند، ارائه گردید.

- acoustic signals,” *Scientific Reports*, vol. 11, no. 1, p. 23062.
21. Feng, S., Ma, S., Zhu, X. & Yan, M. 2024. “Artificial Intelligence-Based Underwater Acoustic Target Recognition: A Survey,” *Remote Sensing*, vol. 16, no. 17, p. 3333.
  22. Li, H., Cheng, Y., Dai, W. & Li, Z. 2014. “A method based on wavelet packets-fractal and SVM for underwater acoustic signals recognition,” in 2014 12th International Conference on Signal Processing (ICSP): IEEE, pp. 2169-2173.
  23. De Moura N. N. & De Seixas, J. M. 2015. “Novelty detection in passive sonar systems using support vector machines,” in 2015 Latin America Congress on Computational Intelligence (LA-CCI), IEEE, pp. 1-6.
  24. Yao Q. et al., 2023. “Recognition method for underwater imitation whistle communication signals by slope distribution,” *Applied Acoustics*, vol. 211, p. 109531.
  25. Sherin, B. & Supriya, M. 2015. “Selection and parameter optimization of SVM kernel function for underwater target classification,” in 2015 IEEE Underwater Technology (UT), IEEE, pp. 1-5.
  26. Wang, B., Wu, C., Zhu, Y., Zhang, M., Li, H. & Zhang, W. 2021. “Ship Radiated Noise Recognition Technology Based on ML-DS Decision Fusion,” *Computational Intelligence and Neuroscience*, vol. 2021, no. 1, p. 8901565.
  27. Liu, F., Li, G. & Yang, H. 2024. “Application of multi-algorithm mixed feature extraction model in underwater acoustic signal,” *Ocean Engineering*, vol. 296, p. 116959.
  28. Li, Y.-X., Jiao, S.-B., Geng, B., Zhang, Q. & Zhang, Y.-M. 2022. “A comparative study of four nonlinear dynamic methods and their applications in classification of ship-radiated noise,” *Defence Technology*, vol. 18, no. 2, pp. 183-193.
  29. Jin, S.-Y., Su, Y., Guo, C.-J., Fan, Y.-X. & Tao, Z.-Y. 2023. “Offshore ship recognition based on center frequency projection of improved EMD and KNN algorithm,” *Mechanical Systems and Signal Processing*, vol. 189, p. 110076.
  30. Quraishi, S. J., Singh, M., Prasad, S. K., Arora, K., Pathak, S. & Singh, A. 2023. “A Machine Learning Approach to Rock and Mine Classification in Sonar Systems Using Logistic Regression,” in 2023 3rd International Conference on Technological Advancements in Computational Sciences (ICTACS), IEEE, pp. 462-468.
  31. Mousavipour, F. & Mosavi, M. R. 2023. “Sonar data classification using neural network trained by hybrid dragonfly and chimp optimization algorithms,” *Wireless Personal Communications*, vol. 129, no. 1, pp. 191-208.
  32. Mahale, V. P., Chanda, K., Chakraborty, B., Salkar, T. & Sreekanth, G. 2023. “Biodiversity assessment using passive acoustic recordings from off-reef location—Unsupervised learning to classify fish vocalization,” *The Journal of the Acoustical Society of America*, vol. 153, no. 3, pp. 1534-1553.
  33. Sun, Y., Yuan, P. & Li, G. 2020. “Research on Classification of Underwater Acoustic Signals,” *Journal of Systems*, vol. 284, p. 111313.
  6. Fortunato, S. 2010. “Community detection in graphs,” *Physics reports*, vol. 486, no. 3-5, pp. 75-174.
  7. Reihanian, A. 2014. “To Propose a New Framework for Topic-oriented Community Detection based on a Semantic Network (MSc Thesis in Persian),” Master of Science, Department of Computer and Information Technology, Mazandaran University of Science and Technology.
  8. Reihanian, A. 2018. “Design and Implementation of a New Framework for Community Detection in Social Networks with Node Attributes using Metaheuristic Algorithms (PhD Thesis in Persian),” Doctor of Philosophy, Department of Computer Engineering, University of Tabriz.
  9. Jamali, S. M. 2007. “Mining Persian Weblogs’ Social Network (MSc Thesis in Persian),” Master of Science, Department of Computer Engineering, Sharif University of Technology.
  10. Webb, A. R. 2003. *Statistical pattern recognition*. John Wiley & Sons.
  11. Leskovec, J., Lang, K. J. & Mahoney, M. 2010. “Empirical comparison of algorithms for network community detection,” in *Proceedings of the 19th international conference on World wide web*, ACM, pp. 631-640.
  12. Easley D. & Kleinberg, J. 2010. *Networks, crowds, and markets: Reasoning about a highly connected world*. Cambridge University Press.
  13. Newman, M. E. & Girvan, M. 2004. “Finding and evaluating community structure in networks,” *Physical review E*, vol. 69, no. 2, p. 026113.
  14. Newman, M. E. 2004. “Analysis of weighted networks,” *Physical Review E*, vol. 70, no. 5, p. 056131.
  15. Liu, K., Yi, S., Wang, G. & Liu, F. 2017. “Passive target classification based on mode energy difference characteristic of the wavenumber spectrum,” in 2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC): IEEE, pp. 1-4.
  16. Aslam M. A. et al., 2024. “Underwater sound classification using learning based methods: A review,” *Expert Systems with Applications*, vol. 255, p. 124498.
  17. Jiang, J., Wu, Z., Lu, J., Huang, M. & Xiao, Z. 2021. “Interpretable features for underwater acoustic target recognition,” *Measurement*, vol. 173, p. 108586.
  18. Zelada Leon, A., Huvenne, V. A., Benoist, N. M., Ferguson, M., Bett, B. J. & Wynn, R. B. 2020. “Assessing the repeatability of automated seafloor classification algorithms, with application in marine protected area monitoring,” *Remote Sensing*, vol. 12, no. 10, p. 1572.
  19. Harakawa, R., Ogawa, T., Haseyama, M. & Akamatsu, T. 2018. “Automatic detection of fish sounds based on multi-stage classification including logistic regression via adaptive feature weighting,” *The Journal of the Acoustical Society of America*, vol. 144, no. 5, pp. 2709-2718.
  20. Gomez, B. & Kadri, U. 2021. “Earthquake source characterization by machine learning algorithms applied to

46. Ren, J., Xie, Y., Zhang, X. & Xu, J. 2022. "UALF: A learnable front-end for intelligent underwater acoustic classification system," *Ocean Engineering*, vol. 264, p. 112394.
47. Tian, S.-Z., Chen, D.-B., Fu, Y. & Zhou, J.-L. 2023. "Joint learning model for underwater acoustic target recognition," *Knowledge-Based Systems*, vol. 260, p. 110119.
48. Alouani, Z., Hmamouche, Y., El Khamlichi, B. & Seghrouchni, A. E. F. 2022. "A spatio-temporal deep learning approach for underwater acoustic signals classification," in 2022 18th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), IEEE, pp. 1-7.
49. Yang, H., Huang, Y. & Liu, Y. 2022. "Spatial Attention Deep Convolution Neural Network for Call Recognition of Marine Mammal," in *International Conference on Autonomous Unmanned Systems*, Springer, pp. 2725-2733.
50. Feng, S. & Zhu, X. 2022. "A transformer-based deep learning network for underwater acoustic target recognition," *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1-5.
51. Gong, Y., Chung, Y.-A. & Glass, J. 2021. "Ast: Audio spectrogram transformer," *arXiv preprint arXiv:2104.01778*.
52. Li, P., Wu, J., Wang, Y., Lan, Q. & Xiao, W. 2022. "STM: Spectrogram transformer model for underwater acoustic target recognition," *Journal of Marine Science and Engineering*, vol. 10, no. 10, p. 1428.
53. Liu et al., Z. 2021. "Swin transformer: Hierarchical vision transformer using shifted windows," in *Proceedings of the IEEE/CVF international conference on computer vision*, pp. 10012-10022.
54. Wu, F., Yao, H. & Wang, H. 2024. "Recognizing the State of Motion by Ship-Radiated Noise Using Time-Frequency Swin-Transformer," *IEEE Journal of Oceanic Engineering*.
55. Yao, H., Gao, T., Wang, Y., Wang, H. & Chen, X. 2024. "Mobile\_ViT: Underwater Acoustic Target Recognition Method Based on Local-Global Feature Fusion," *Journal of Marine Science and Engineering*, vol. 12, no. 4, p. 589.
56. Xue, L., Zeng, X. & Jin, A. 2022. "A novel deep-learning method with channel attention mechanism for underwater target recognition," *Sensors*, vol. 22, no. 15, p. 5492.
57. Honghui, Y., Junhao, L. & Meiping, S. 2022. "Underwater acoustic target multi-attribute correlation perception method based on dep learning," *Applied Acoustics*, vol. 190, p. 108644.
58. Shen, S., Yang, H., Li, J., Xu, G. & Sheng, M. 2018. "Auditory inspired convolutional neural networks for ship type classification with raw hydrophone data," *Entropy*, vol. 20, no. 12, p. 990.
59. Yang, Y. 2017. "A signal theoretic approach for envelope analysis of real-valued signals," *IEEE Access*, vol. 5, pp. 5623-5630.
60. Bradbury, J. 2000. "Linear predictive coding," *Mc G. Hill*.
34. Wang, P. & Peng, Y. 2020. "Research on feature extraction and recognition method of underwater acoustic target based on deep convolutional network," in 2020 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA), IEEE, pp. 863-868.
35. Doan, V.-S., Huynh-The, T. & Kim, D.-S. 2020. "Underwater acoustic target classification based on dense convolutional neural network," *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1-5.
36. Qi, P., Yin, G. & Zhang, L. 2024. "Underwater acoustic target recognition using RCRNN and wavelet-auditory feature," *Multimedia Tools and Applications*, vol. 83, no. 16, pp. 47295-47317.
37. Yao, Q., Wang, Y. & Yang, Y. 2023. "Underwater acoustic target recognition based on data augmentation and residual CNN," *Electronics*, vol. 12, no. 5, p. 1206.
38. Yang, S., Xue, L., Hong, X. & Zeng, X. 2023. "A lightweight network model based on an attention mechanism for ship-radiated noise classification," *Journal of Marine Science and Engineering*, vol. 11, no. 2, p. 432.
39. Cai, W., Zhu, J., Zhang, M. & Yang, Y. 2022. "A parallel classification model for marine mammal sounds based on multi-dimensional feature extraction and data augmentation," *Sensors*, vol. 22, no. 19, p. 7443.
40. Tian, G., Haiyang, Y., Haiyan, W., Fan, W. & Xiao, C. 2023. "CA\_MobileNetV2 for Underwater Acoustic Target Recognition," in 2023 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), IEEE, pp. 1-5.
41. Jiang, Z., Zhao, C. & Wang, H. 2022. "Classification of underwater target based on S-ResNet and modified DC-GAN models," *Sensors*, vol. 22, no. 6, p. 2293.
42. Yan, C. et al., 2023. "Underwater target recognition using a lightweight asymmetric convolutional neural network," in *Proceedings of the 17th International Conference on Underwater Networks & Systems*, pp. 1-8.
43. Jin, A. & Zeng, X. 2023. "A novel deep learning method for underwater target recognition based on res-dense convolutional neural network with attention mechanism," *Journal of Marine Science and Engineering*, vol. 11, no. 1, p. 69.
44. Wang, B., Zhang, W., Zhu, Y., Wu, C. & Zhang, S. 2023. "An underwater acoustic target recognition method based on AMNet," *IEEE Geoscience and Remote Sensing Letters*, vol. 20, pp. 1-5.
45. Chen, L., Liu, F., Li, D., Shen, T. & Zhao, D. 2022. "Underwater acoustic target classification with joint learning framework and data augmentation," in 2022 5th International Conference on Artificial Intelligence and Big Data (ICAIBD), IEEE, pp. 23-28.

79. "Community Detection Toolbox - File Exchange - MATLAB Central." (accessed).
61. Logan, B. 2000. "Mel frequency cepstral coefficients for music modeling," in *Ismir*, vol. 270, pp. 1-11.
62. Ahmed, N., Natarajan, T. & Rao, K. R. 1974. "Discrete cosine transform," *IEEE transactions on Computers*, vol. 100, no. 1, pp. 90-93.
63. Abdi, H. & Williams, L. J. 2010. "Principal component analysis," *Wiley interdisciplinary reviews: computational statistics*, vol. 2, no. 4, pp. 433-459.
64. Thomson, D. J. 1982. "Spectrum estimation and harmonic analysis," *Proceedings of the IEEE*, vol. 70, no. 9, pp. 1055-1096.
65. Alexander, W. & Williams, C. M. 2016. *Digital Signal Processing: Principles, Algorithms and System Design*. Academic Press.
66. Bogert, B. P., Healy, M. J. R. & Tukey, J. W. 1963. "The quefrency alanalysis of time series for echoes; Cepstrum, pseudo-autocovariance, cross-cepstrum and saphe crack-ing," *Time series analysis*, pp. 209-243.
67. Oppenheim, A. V. & Schaffer, R. W. 2004. "From frequency to quefrency: A history of the cepstrum," *IEEE signal processing Magazine*, vol. 21, no. 5, pp. 95-106.
68. Bishop, M. P., Young, B. W., Huo, D. & Chi, Z. 2020. "Spatial Analysis and Modeling in Geomorphology,".
69. Esfetanaj, N. N. & Nojavan, S. 2018. "The use of hybrid neural networks, wavelet transform and heuristic algorithm of WIPSO in smart grids to improve short- term prediction of load, solar power, and wind energy," in *Operation of Distributed Energy Resources in Smart Distribution Networks*: Elsevier, pp. 75-100.
70. Xiao, Z. 2012. "Compositing, smoothing, and gap- filling techniques," *Advanced remote sensing terrestrial information extraction and applications*, pp. 75-90.
71. "What is a Notch Filter? - everything RF." (accessed).
72. "2-D correlation coefficient - MATLAB corr2 - Math-Works." (accessed).
73. Blondel, V. D., Guillaume, J.-L., Lambiotte, R. & Lefebvre, E. 2008. "Fast unfolding of communities in large networks," *Journal of Statistical Mechanics: Theory and Experiment*, vol. 2008, no. 10, p. P10008.
74. Lancichinetti, A., Fortunato, S. & Kertész, J. 2009. "Detecting the overlapping and hierarchical community structure in complex networks," *New Journal of Physics*, vol. 11, no. 3, p. 033015.
75. Hespanha, J. P. 2004. "An efficient matlab algorithm for graph partitioning," Santa Barbara, CA, USA: University of California.
76. Le Martelot, E. & Hankin, C. 2013. "Fast multi-scale detection of relevant communities in large-scale networks," *The Computer Journal*, vol. 56, no. 9, pp. 1136-1150.
77. Simon, H. A. 1962. "The Architecture of Complexity," *Proceedings of the American Philosophical Society*, vol. 106, no. 6, pp. 467-482.
78. Riehl, J. R. & Hespanha, J. P. 2007. "Cooperative graph search using fractal decomposition," in *2007 American Control Conference*, IEEE, pp. 2557-2562.