

ارائه یک الگوریتم سه مرحله‌ای برای تشخیص جوامع مبتنی بر گره‌های ناهنجار مرکزی

سعید تقوی افشرد (نویسنده مسئول)^۱، محمدحسن محمدباقرزاده^۲

^۱ عضو هیئت علمی موسسه آموزش عالی رشدیه، شهر تبریز taghavi.afshard@gmail.com

^۲ دانشجوی کارشناسی ارشد موسسه آموزش عالی رشدیه، شهر تبریز mh.b.zadeh@gmail.com

چکیده

تشخیص اجتماع یک مساله پیچیده و مهم در مطالعه ساختار شبکه و فهم ویژگی‌ها، برای استخراج اطلاعات شبکه است. این مسئله، به کرات مورد توجه پژوهشگران مختلف قرار گرفته است؛ اما هم‌چنان تشخیص جوامع با دقت و کیفیت بالا در شبکه‌های پیچیده، یکی از مسائل باز این حوزه می‌باشد. به طور کلی، تشخیص درست جوامع به شناسایی دقیق گره‌های مرکزی وابسته است. تاکنون در تشخیص گره‌های مرکزی، بیشتر موارد گره‌های با درجه بالا و فاصله بیشتر مد نظر گرفته شده است اما در این پژوهش برای اولین بار، گره‌های مرکزی در شبکه‌های پیچیده بر اساس ناهنجاری گره‌ها شناسایی شدند. منظور از گره‌های ناهنجار، گره‌هایی هستند که رفتار آن‌ها، از رفتار غالب گره‌های شبکه دور بوده و می‌تواند متعلق به یک گره تاثیرگذار در شبکه یا یک اسپر باشد. در این پژوهش، در گام اول بعد از شناسایی گره‌های مرکزی با بررسی میزان ناهنجاری گره، در گام دوم از الگوریتم انتشار برچسب، برای دسته‌بندی اجتماع‌ها استفاده شده و نهایتاً در گام سوم، پیش اجتماع‌های تشخیص داده شده در گام دوم، با هم ترکیب می‌شوند. آزمایش‌ها و شبیه‌سازی‌ها در محیط متلب نشان می‌دهد که روش پیشنهادی، از نرخ صحت، معیار ماژولاریتی و اطلاعات متقابل نرمال شده بهبود یافته‌تری نسبت به پژوهش‌های پیشین برخوردار است.

واژه‌های کلیدی

تشخیص اجتماع، گره‌های مرکزی، گره‌های ناهنجار، انتشار برچسب، الگوریتم آکوگلو

۱. مقدمه

ما در عصر اطلاعات زندگی می‌کنیم؛ ترابایت‌ها یا پتابایت‌ها داده، هر روز در بدهای مختلف زندگی ما، تولید می‌شوند. رشد سریع و انفجاری داده، در دسترس بودن گسترده منابع تولید داده مانند شبکه‌های اجتماعی آنلاین، عصر ما را به عصر استخراج اطلاعات و دانش ساخت‌یافته پشت این داده‌ها، تبدیل کرده است [۱]. یکی از انواع داده‌ها، گراف‌ها هستند. از ساختار داده گراف، برای مدل‌سازی شبکه‌های موجود در جهان واقعی استفاده می‌شود. این مدل‌سازی، امکان توصیف سیستم‌های پیچیده‌ی جهان واقعی مانند شبکه‌های اجتماعی، شبکه‌ی اینترنت، شبکه‌ی پروتئین و شبکه‌های عصبی را امکان‌پذیر می‌سازد [۷, ۳]. از سوی دیگر آنالیز شبکه‌ها، در حوزه‌های مختلف مانند بیوتکنولوژی، علوم کامپیوتر، علوم اجتماعی و ... دارای کاربردهای فراوان است؛ برای مثال آنالیز ساختار بخش‌های مختلف مغز، دارای وجوه تشابه فراوانی با ساختار گراف‌های شبکه‌های اجتماعی مانند فیس‌بوک دارد [۴]. بنابراین، این گراف‌ها، گراف‌های تصادفی نیستند و الگوهای حاکم بر آن‌ها، قابل تحلیل و کشف است. یکی از این الگوها، پیدا کردن زیرگراف‌هایی است که اعضای آن زیرگراف با هم ارتباط متصل‌تر دارند در حالی که با سایر اعضای گراف ارتباطشان کمتر است. این نوع زیرگراف‌ها، اصطلاحاً جامعه یا اجتماع در گراف نامیده می‌شوند. پیدا کردن چنین جوامعی می‌تواند اطلاعات پنهان در مورد جامعه، ساختار جوامع، افراد تاثیرگذار، روابط بین موجودیت‌ها و غیره را در اختیار ما قرار دهد که در نهایت از این اطلاعات می‌توان به منظور حفظ امنیت اعضای جامعه، اهداف سیاسی، تحلیلهای تجاری و ... استفاده کرد [۵, ۶].

۱.۱. بیان مسئله

در سال‌های اخیر، تشخیص اجتماع در شبکه‌های پیچیده، به کرات مورد توجه قرار گرفته است. به طور کلی، می‌توان این روش‌ها را به دو دسته سراسری و محلی تقسیم‌بندی کرد. روش‌های سراسری در تشخیص اجتماع، کل ساختار گراف را در نظر می‌گیرند. این روش‌ها پیچیدگی زمانی بالا دارند و معمولاً الگوریتم‌های مفیدی نیستند. زیرا مجموعه داده‌های واقعی، مانند مجموعه داده‌های توئیتر و فیس‌بوک، مجموعه داده‌های میلیونی هستند. اما مجموعه روش‌های محلی، بر اساس معیارهای ساختاری محلی گراف به تشخیص اجتماع می‌پردازند؛ این مجموعه روش‌ها، معمولاً پیچیدگی زمانی نزدیک به خطی دارند؛ اما اندازه داده‌های مربوط به شبکه‌های پیچیده، رشد روز افزونی دارند و تشخیص اجتماع حتی با یک الگوریتم با پیچیدگی زمانی نزدیک به خطی، بر روی یک کامپیوتر واحد امکان‌پذیر نیست. بنابراین ارائه الگوریتم‌های با پیچیدگی زمانی پایین‌تر و نرخ صحت بالا برای تشخیص اجتماع، بسیار موثر واقع می‌شود. تجزیه و تحلیل شبکه کاربردهای زیادی در زمینه بیوتکنولوژی، علوم کامپیوتر، علوم انسانی، علوم طبیعی و اجتماعی و سیستم‌های مختلف مهندسی دارد. به عنوان مثال، ساختار شبکه‌ای ارتباطات در بخش‌های مختلف مغز انسان شباهت‌های ساختاری جالبی با نمودار فیس بوک دارد. همچنین الگوی توزیع بیماری مشابه الگوی انتشار شایعه در شبکه‌های اجتماعی است. با گسترش سریع اینترنت و شبکه‌های اجتماعی مجازی، اهمیت شبکه‌ها در زندگی روزمره بیش از پیش احساس می‌شود. در عصر داده‌های بزرگ، نمودارهای اجتماعی در ابعاد و دامنه‌های وسیع تری مورد بحث قرار می‌گیرند. شبکه مجموعه‌ای از گره‌ها و پیوندهای متقابل آن‌ها است و بر اساس ماهیت پدیده‌ها را می‌توان به نمودارهای وزن‌دار یا بدون وزن و جهت‌دار یا غیر جهت‌دار تقسیم کرد. جالب است که شبکه‌های دنیای واقعی مختلف ویژگی‌های ساختاری و دینامیکی مشابهی دارند [۴].

۲.۱. اهمیت و ضرورت انجام تحقیق

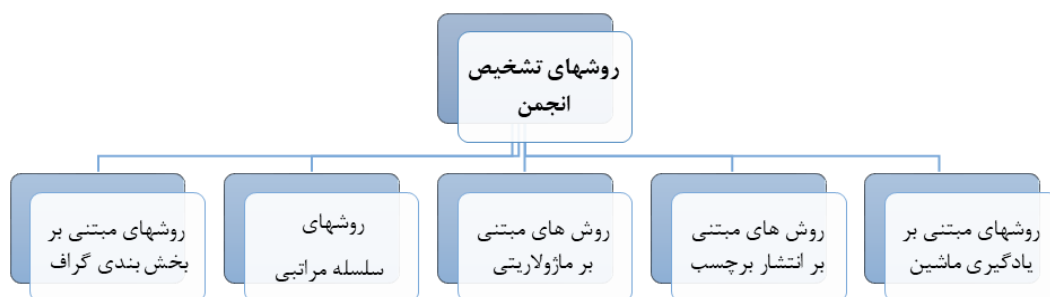
تشخیص اجتماع یک مساله سخت و مهم در مطالعه ساختار شبکه و فهم ویژگی‌ها، برای استخراج اطلاعات شبکه است [۱]. می‌توان از تشخیص اجتماع در شبکه‌های پیچیده، تحت عنوان خوشه‌بندی این شبکه‌ها نام برد. یعنی در تشخیص اجتماع، نهایتاً گره‌های با ویژگی یکسان دور هم جمع می‌گردند. با شناسایی این اجتماع‌ها و افراد متعلق به چند اجتماع، می‌توان سرعت انتشار اطلاعات در شبکه را افزایش داد [۱, ۸]. هم‌چنین بررسی چند جامعه، می‌تواند منجر به دست آوردن دید کلی نسبت به کل شبکه گردد و می‌توان روابط بین گره‌های شبکه پیچیده را تحلیل کرد. انتخاب معیار مناسب برای سنجش میزان تشابه و هم‌چنین نحوه تعیین اهمیت گره در کارایی الگوریتم تشخیص اجتماع، بسیار موثر است. در پژوهش‌های پیشین، با در نظر گرفتن سناریوهای مختلف اجتماعی، مانند این که "افراد دور گره‌های مهم در شبکه جمع می‌گردند" [۳]، تلاش می‌شود تا گره‌های با درجه بالا یا گره‌هایی با بیش‌ترین فاصله را [۳] که

اصطلاحاً گره‌های پراهمیت می‌نامند، شناسایی کنند. اما اکثریت الگوریتم‌های ارائه شده با مشکل پیچیدگی زمان بالا و دقت پایین روبرو هستند. از سوی دیگر، با در نظر گرفتن این واقعیت که حجم داده‌ها، به‌صورت مداوم در حال افزایش بوده و جامعه امروزی نیازمند پاسخ سریع در پردازش داده‌ها است، باید الگوریتم‌هایی با پیچیدگی زمانی کم و دقت بالا ارائه گردد. کیفیت جامعه تشخیص داده شده، به شدت به کیفیت گره‌های مرکزی شناسایی شده وابسته است. در روش‌های پیشین، همواره گره‌های با درجه بالا، فاصله بیشتر و غیره را به عنوان گره‌های مرکزی در نظر می‌گرفتند، در حالی که اکثر روش‌های موجود دارای معایبی مانند دقت پایین، مقیاس‌پذیری ضعیف و بی‌ثباتی در نتایج هستند [۴]. در این مقاله برای اولین بار، تعریف گره‌های پراهمیت در شبکه‌های پیچیده بر اساس گره‌های ناهنجار خواهد بود. یعنی گره‌هایی به عنوان گره مرکزی شناخته خواهند شد که رفتار آن‌ها، از رفتار غالب گره‌های شبکه دور است.

۲. مروری بر تحقیقات پیشین

مفهوم شبکه اجتماعی بعد از به شهرت رسیدن وبسایت‌هایی مانند فیس‌بوک، اینستاگرام، توئیتر و ... مورد توجه قرار گرفت. دو ویژگی اصلی شبکه‌های اجتماعی، وجود موجودیت‌های متعدد و ارتباطات بین این موجودیت‌ها است. در این شبکه‌ها، موجودیت‌ها می‌توانند افراد و ارتباطات بین این موجودیت‌ها می‌توانند دوستی بین افراد باشند. همچنین موجودیت‌ها می‌توانند وبسایت‌ها و سازمان‌ها و ارتباطات بین آن‌ها می‌توانند تعاملات یا خرید و فروش بین این موجودیت‌ها باشند [۹، ۱۰]. به طور کلی از ساختار داده گراف، برای مدل‌سازی شبکه‌های اجتماعی استفاده می‌شود. موجودیت‌ها در این مدل‌سازی به عنوان رئوس گراف و ارتباطات بین موجودیت‌ها به عنوان یال‌های گراف شناخته می‌شوند. از این مدل‌سازی در پدیده‌های دنیای واقعی تحت عنوان شبکه‌های پیچیده نام برده می‌شود که در ادامه شرح داده خواهد شد [۱۰].

یک گراف، شامل مجموعه‌ای ناتهی از رئوس و یال‌ها است. در علوم رایانه اغلب از این ساختار داده برای مدل‌سازی شبکه‌های موجود در جهان واقعی مانند شبکه‌های اجتماعی، شبکه‌ی اینترنت، شبکه‌ی پروتئین، شبکه‌های عصبی و غیره استفاده می‌شود [۱۱]. ساختار داده گراف استفاده شده برای مدل‌سازی پدیده‌های دنیا واقعی، شبکه‌های پیچیده نامیده می‌شود. این دسته شبکه‌ها از لحاظ توپولوژیکی دارای ویژگی‌هایی مانند بالا بودن ضریب خوشه‌بندی، پیروی درجته‌ها از قانون توانی و ... هستند (در ادامه توضیح داده می‌شود)؛ در حالی که دسته دیگر گراف‌ها یعنی گراف‌های تصادفی دارای درجات مشابه و توزیع یال همگون هستند [۱۲]. الگوریتم‌های کشف جوامع، طیف گسترده‌ای دارند. در شکل ۱ یک بخش‌بندی از این روش‌ها، آورده شده است.



شکل ۱. بخش‌بندی پژوهش‌های پیشین در حوزه تشخیص اجتماع در شبکه‌های اجتماعی

۱.۲. روش‌های سلسله مراتبی [۱۸]

خوشه‌بندی سلسله مراتبی یکی از رایج‌ترین روش‌های تشخیص اجتماع برای شبکه‌های اجتماعی است. در این روش مرتباً یال‌های بین دو گره به صورت تصادفی انتخاب می‌شوند تا در نهایت، خوشه‌ها تشکیل شوند، اما این روش دارای معایبی است. بدین ترتیب که در مورد گره‌های واسطه بین اجتماع‌ها، احتمال ترکیب وجود دارد در حالیکه این دو گره در دو خوشه کاملاً متمایز هستند. برای حل این مشکل در خوشه‌بندی با الگوریتم سلسله مراتبی، معمولاً چندین مرتبه این الگوریتم را اجرا می‌کنند و تکراری که بیش‌ترین خوشه‌های منسجم را ارائه دهد، به عنوان پاسخ برگردانده می‌شود. البته روش دیگری نیز هست که در آن، اهمیت گره با استفاده از معیارهایی مانند نیومن و یا معیار مازولاریتی سنجیده می‌شود و خوشه‌بندی سلسله مراتبی با توجه به این معیارها انجام می‌گیرد. برای مثال در این تحقیق، با استفاده

از معیار سورنسن، گره‌های مرکزی شناسایی شده و با استفاده از الگوریتم خوشه‌بندی سلسله‌مراتبی، گره‌های اطراف گره مرکزی بررسی می‌شوند، با این تفاوت که انتخاب یال‌ها تصادفی نخواهد بود، بلکه بر اساس معیار فاصله، اهمیت یال‌ها محاسبه می‌شود و در نهایت اگر اندازه خوشه‌های به دست آمده کم‌تر از حد آستانه باشد، خوشه‌ها ترکیب خواهند شد.

۲.۲. روش بخش‌بندی گراف [۲۴]

در این روش سعی می‌شود گراف به k قسمت از پیش تعیین شده با اندازه و تعداد گره‌های معلوم تقسیم‌بندی شود، به طوری که تعداد یال‌های بین جوامع کمینه باشد [۲۳]. به طور کلی، روش‌های بخش‌بندی گراف در دو دسته کلی جای می‌گیرند؛ روش‌های بخش‌بندی طیفی که از ماتریس لاپلاسیس گراف و بردار ویژه آن برای بخش‌بندی استفاده می‌کند؛ و الگوریتم کرنیگان-لین که تلاش می‌کند ساختار جامعه را بر روی بخش‌بندی اولیه گراف به شکل حریصانه بهینه کند [۲۴]. تابع سود در این الگوریتم برابر با مجموع یال‌های درون جامعه منتهای مجموع یال‌های بین جوامع است. ضعف اصلی الگوریتم کرنیگان-لین، وابسته بودن به اندازه و تعداد اولیه جوامع در مرحله ابتدایی الگوریتم است. این مشکل به خصوص در مجموعه داده‌های واقعی، رخ می‌نماید. بعدها، توسعه‌هایی در این الگوریتم داده شد تا زمانی که تعداد و اندازه جوامع مشخص نباشد نیز با جابه‌جایی یک گره واحد به طور همزمان به سایر جوامع، تشخیص جوامع انجام گردد اما این الگوریتم همچنان دارای کاستی‌هایی است که معمولاً در زمان و تشخیص جوامع، ضعیف عمل می‌کند.

۳.۲. روش‌های مبتنی بر ماژولاریتی [۷]

اگر چه الگوریتم‌های زیادی برای خوشه‌بندی ارائه شده است، اما این الگوریتم‌ها بدون معیاری برای محاسبه کیفیت اجتماع‌ها، ناقص هستند. در سال ۲۰۰۴، نیومن-گیروان [۷] معیار ماژولاریتی را در این راستا معرفی کردند که در آن ماژولاریتی برابر با تعداد یال‌ها در آن اجتماع منتهای تعداد یال مورد نظر مطابق قانون توانی است و در بازه ۰.۵- تا ۱ قرار دارد [۲۶]. روش‌های مبتنی بر ماژولاریتی، یک روش حریصانه در پیش می‌گیرند که تنها هدف آن‌ها، افزایش میزان ماژولاریتی حاصل از ادغام و یا انتقال گره‌ها در جوامع است. از معایب این روش، گیر کردن در بهینه محلی و اهمیت ندادن این دسته روش‌ها به نقش آن گره در جوامع است؛ برای مثال، مرکزی یا حاشیه‌ای بودن آن گره در روشهای مبتنی بر ماژولاریتی اهمیتی ندارد. برای حل این مشکل در پژوهش ابتدا گره‌های مرکزی بر اساس یک معیار شباهت مشخص می‌شود و در نهایت بر اساس معیار ماژولاریتی، پیش‌اجتماع‌ها ادغام می‌گردند.

۴.۲. روش‌های مبتنی بر انتشار برچسب [۱۹]

این روش یک الگوریتم محلی برای شناسایی اجتماعات ارائه می‌کند، به طوریکه از ساختار محلی و توپولوژیکی خود شبکه کمک می‌گیرد. در الگوریتم انتشار برچسب، در ابتدا هر راس با یک مقدار واحد مقداردهی اولیه می‌شود و در هر چرخه از تکرار الگوریتم، به هر راس برچسبی اختصاص می‌یابد به گونه‌ای که اکثر همسایگان آن راس نیز به آن برچسب اختصاص یافته‌اند. الگوریتم انتشار برچسب مطابق با توضیحات مذکور ادامه می‌یابد تا یک مجموعه متراکم با برچسب یکسان شکل گیرد. در پایان الگوریتم، رؤس با برچسب‌های یکسان با یکدیگر ادغام می‌شوند. لازم به ذکر است که در این الگوریتم نیازی به اطلاع از تعداد و اندازه اجتماعات از قبل نیست و در پایان الگوریتم، تعداد و اندازه اجتماعات بدست می‌آیند [۲۷].

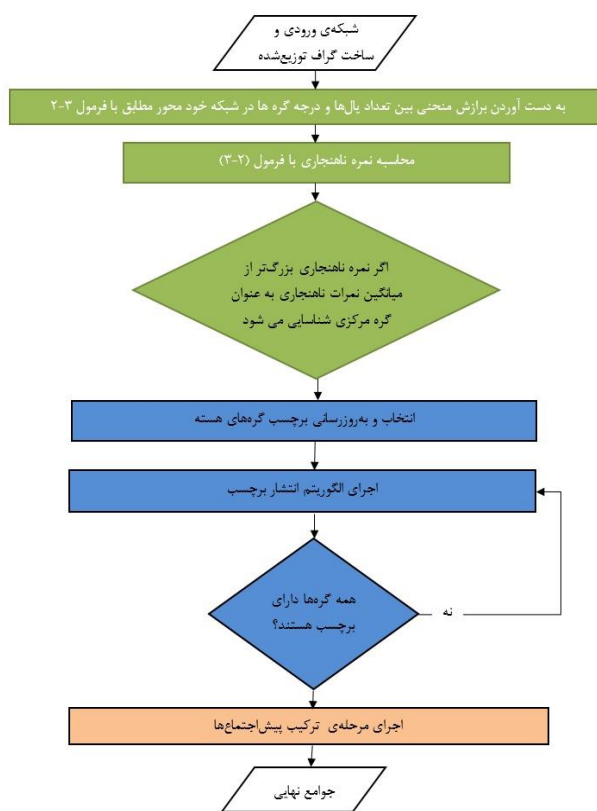
۵.۲. روشهای مبتنی بر یادگیری ماشین [۲۰]

این حوزه در تشخیص اجتماع، حوزه‌ای نو پدید با چشم‌اندازی روشن به حساب می‌آید. توانایی یادگیری عمیق در آموزش ویژگی‌های داده‌های با ابعاد بالا، این امکان را فراهم می‌آورد که این دسته از روش‌ها، در یادگیری الگوهای گراف مانند همسایه‌ها، گره‌ها و غیره نیز موفق عمل کنند [۲۸]. در پژوهش صالحی و همکارانش [۲]، از یک رویکرد سه گامی، با استفاده از یادگیری عمیق به شناسایی اجتماع‌ها در شبکه‌های اجتماعی می‌پردازند. گام‌های این پژوهش بدین صورت است که در گام اول یعنی گشت تصادفی یک مکانیزم برای نمایش گره‌های شبکه به عنوان ورودی قسمت یادگیری عمیق معرفی می‌شود، یعنی در این گام، با شروع از گره i احتمال مشاهده دیگر گره‌ها به عنوان گام بعدی محاسبه می‌شود و به عنوان ورودی به شبکه یادگیری عمیق داده می‌شود. به منظور حل توسط شبکه یادگیری عمیق نیاز است تا وزن‌های مناسب هر لایه و تابع تحریک و بهینه‌ساز تعیین گردند. در این پژوهش از تابع $Relu$ و تابع گرادیان کاهشی

تصادفی به عنوان تابع بهینه‌ساز استفاده شده است و در نهایت بردار ویژگی‌های استخراج شده با استفاده از دو الگوریتم خوشه‌بندی k-mean و DBSCAN خوشه بندی شده‌اند [۲].

۳. روش پیشنهادی

این روش دارای سه گام مهم است که در زیربخش‌های مربوط به هر گام، به جزئیات پرداخته شده است. در گام اول، به شناسایی گره‌های مرکزی خواهیم پرداخت. در گام دوم از الگوریتم انتشار برجسب، استفاده خواهیم کرد و نهایتاً در گام سوم، پیش‌اجتماع‌های تشخیص داده شده در گام دوم، با هم ترکیب خواهند شد. در شکل ۲ فلوچارت کلی روش پیشنهادی آورده شده است.



شکل ۲. فلوچارت روش پیشنهادی

گره‌های هسته نقش بسیار اساسی در شکل‌گیری درست جوامع می‌توانند داشته باشند، زیرا اگر ترتیب صحیح از گره‌ها به عنوان گره‌های هسته انتخاب شود، در مراحل بعدی الگوریتم برجسب جوامع با صحت و اطمینان بیشتری انتخاب خواهد شد و گره‌های کم‌اهمیت‌تر برجسب درستی دریافت خواهند کرد؛ به طور معمول، روند تشخیص این گره‌ها در شبکه‌های پیچیده بر اساس اهمیت گره‌ها در این شبکه‌هاست. تاکنون تعریف این اهمیت بر اساس مفاهیمی مانند درجه بالا، فاصله بیش‌تر، معیار سورنسن بالاتر و ... بود. در این پژوهش برای اولین بار، تعریف گره‌های پراهمیت در شبکه‌های پیچیده بر اساس گره‌های ناهنجار خواهد بود. یعنی گره‌هایی، به عنوان گره مرکزی شناخته خواهند شد که رفتار آن‌ها، از رفتار غالب گره‌های شبکه دور است. دو دسته از گره‌ها، متفاوت با روال عادی هستند یک گره‌های تاثیرگذار (اینفلوئنسر) و دوم گره‌هایی که منزوی، خرابکار و خاص هستند. اگر در تشخیص گره‌های مرکزی، هر دو دسته این گره‌ها در نظر گرفته شود؛ یعنی هم گره‌های با درجه بالا و هم گره‌هایی که دوره خاص خود دارند؛ احتمال افزایش تشخیص اجتماع‌های باکیفیت افزایش می‌یابد؛ زیرا در مورد گره‌های اینفلوئنسر، فلسفه معمول تشخیص اجتماع صادق است؛ اما اگر در کنار این گره‌های اینفلوئنسر، گره‌های خاص مانند گره‌های خلافکار نیز شناخته شوند، مرز تشخیص گره‌ها، بیش‌تر متمیز خواهد بود.

۱.۳. گام اول: تشخیص گره‌های مرکزی

گره‌های مرکزی، مجموعه‌ای از گره‌های مهم و با اهمیت هستند که ویژگی‌های متفاوتی نسبت به سایر گره‌های کم اهمیت دارند. در این پژوهش برای اولین بار، تعریف گره‌های پراهمیت در شبکه‌های پیچیده بر اساس گره‌های ناهنجار خواهد بود و گره‌هایی که رفتار آن‌ها، از رفتار غالب گره‌های شبکه دور باشد، به عنوان گره‌های مرکزی شناخته می‌شود؛ این گره‌های ناهنجار می‌توانند متعلق به یک سلبریتی، اینفلوئنسر یا یک کلاهبردار مالی باشند.

در این پژوهش، شناسایی گره‌های مرکزی بر اساس روش آکوگلو [۴۴] که یکی از پژوهش‌های پایه تشخیص ناهنجاری است، انجام خواهد گرفت. در پژوهش آکوگلو، یک دایره اطراف یک گره تعریف می‌گردد که شامل خود گره، همسایه‌های مستقیم و تمامی ارتباطات ما بین این گره‌ها است. این دایره اصطلاحاً شبکه خودمحور نامیده می‌شود و نشان می‌دهند که بین تعداد یال‌ها و رأس‌ها در یک شبکه خودمحور، رابطه‌نمایی مطابق رابطه (۱) برقرار است:

$$E_i \varphi N_i^\alpha \quad 1 < \alpha <= 2 \quad (1)$$

که در آن E_i ، تعداد یال‌های شبکه خودمحور گره i و N_i تعداد گره‌های شبکه خودمحور گره i است. در این روش برازش منحنی، بین تعداد یال‌ها در شبکه خودمحور و درجه گره‌ها به دست می‌آید و برای هر گره i در رگرسیون توانی نمره «دور بودن» را مطابق با رابطه (۲) محاسبه می‌شود:

$$\text{outline}(i) = \frac{\max(y_i \cdot C_{x_i}^\theta)}{\min(y_i \cdot C_{x_i}^\theta)} * \log|y_i - C_{x_i}^\theta| + 1 \quad (2)$$

که در آن y_i مقدار حقیقی معیار، $C_{x_i}^\theta$ مقدار محاسبه شده معیار توسط رگرسیون، $\max(y_i \cdot C_{x_i}^\theta)$ مقدار محاسبه شده توسط بازه حداکثری رگرسیون (رگرسیون در دو بازه حداکثری و حداقلی تخمین زده می‌شود) و $\min(y_i \cdot C_{x_i}^\theta)$ مقدار محاسبه شده توسط بازه حداقلی رگرسیون می‌باشد.

در اصل رابطه (۲) فاصله تا خط رگرسیون به دست آمده را تخمین می‌زند و در نهایت از الگوریتم عامل دور افتاده محلی برای تشخیص ناهنجاری استفاده شده و گره‌ها بر اساس نمره ناهنجاری مرتب می‌شوند. N نقطه که نمره ناهنجاری آن‌ها از میانگین نمره ناهنجاری کل گره‌ها بیش‌تر باشد به عنوان گره‌های مرکزی شناسایی خواهند شد.


الگوریتم عامل دورافتاده محلی بر مبنای مفهوم چگالی محلی بنا شده و در آن محلی بودن بر اساس k نزدیک‌ترین همسایگی تعیین می‌شود که فاصله آن‌ها برای تخمین چگالی مورد استفاده قرار می‌گیرد. با مقایسه چگالی محلی یک شی با چگالی‌های همسایه‌های آن می‌توان نواحی دارای چگالی مشابه و نقاطی که اساساً چگالی کمتری نسبت به همسایه‌های خود دارند را تعیین کرد. این موارد به عنوان دورافتادگی (داده پرت) در نظر گرفته می‌شوند. چگالی محلی به وسیله فاصله معمولی که یک نقطه داده توسط همسایه‌های خود «دسترسی‌پذیر» است، تخمین زده می‌شود.

با یک مثال بر روی مجموعه داده واقعی دلفین گره‌های مرکزی شناسایی می‌شوند. در شکل ۳ گراف ارتباطات این دیتاست و گره‌های مرکزی بر اساس نمره ناهنجاری آورده شده است. با استفاده از این روش، هشت گره مرکزی مطابق با جدول ۱ شناسایی می‌شود. حال آن که با استفاده از روش‌هایی مانند بیش‌ترین درجه و فاصله، ۴۱ گره مرکزی شناسایی خواهد شد.

ششمین همایش بین‌المللی افق‌های نوین در مهندسی برق، کامپیوتر و مکانیک

6th International Conference on the New Horizons in Electrical Engineering, Computer and Mechanical

www.mhconf.ir



شکل ۳. گره‌های مرکزی شناسایی شده بر اساس روش اکوگلو و نمره ناهنجاری

در این دیتاست، گره‌های {۶۲، ۴۱، ۳۰، ۲۰، ۱۸، ۱۵، ۹، ۶} به عنوان گره‌های مرکزی شناسایی شدند. در جدول ۱ مشخصات این نقاط آورده شده است.

جدول ۱. مشخصات گره‌های مرکزی

گره	تعداد یال در شبکه خودمحور	تعداد گره در شبکه خودمحور
۶	۷	۴
۹	۱۰	۶
۱۵	۲۹	۱۲
۱۸	۱۷	۹
۲۰	۷	۴
۳۰	۱۸	۹
۴۱	۱۵	۸
۶۲	۳	۳

۲.۳. گام دوم: انتشار برچسب

الگوریتم انتشار برچسب سنتی به این صورت است که در این الگوریتم، هر گره را با یک برچسب منحصر به فرد اولیه مقداردهی کرده و به برچسب اجازه انتشار از طریق شبکه را می‌دهد؛ یک گره به تصادف انتخاب می‌شود، سپس گره انتخابی، برچسب خود را مطابق با برچسب بالاترین تعداد رخداد در میان همسایگان، قرار خواهند داد. اگر تعداد رخداد برچسب در بین همسایگان به تعداد مساوی باشد یک برچسب به تصادف انتخاب خواهد شد.

اما ما در این پژوهش، با تغییراتی در الگوریتم انتشار برچسب، از یک الگوریتم جدید استفاده خواهیم کرد. بدین صورت که بعد از شناسایی گره‌های مرکزی، هر گره مرکزی برچسب یا رنگ متمایز به خود می‌گیرد؛ سپس در گره‌های همسایگان گره‌های مرکزی، بیشترین میزان شباهت با امتیاز آنومالی محاسبه می‌شود، برای مثال در دیتاست مثال قبل معیارهای شباهت محاسبه شده برای چند گره با بیشترین امتیاز از قرار جدول ۲ است.

ششمین همایش بین‌المللی افق های نوین در مهندسی برق، کامپیوتر و مکانیک


6th International Conference on the New Horizons in Electrical Engineering, Computer and Mechanical

www.mhconf.ir

جدول ۲. محاسبه امتیاز آنومالی دیتاست دلفین

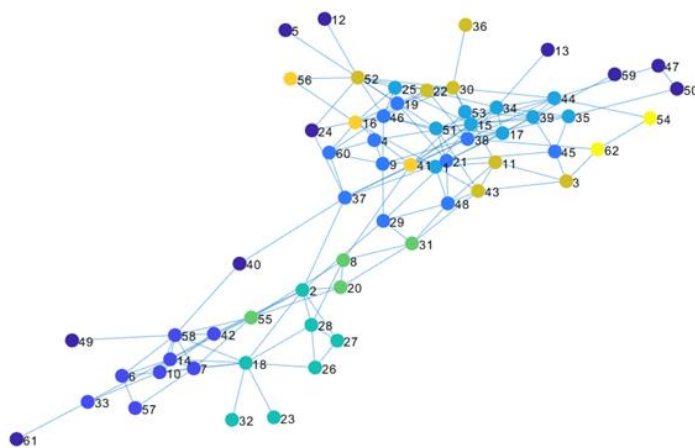
امتیاز	گره
۱۸۰۰	۱۴
۱۷۰۰	۵۷
۱۵۰۰	۵۸
۱۴۰۰	۱۰

و در نهایت مطابق شکل گره ۱۴ به عنوان برنده اولین مرحله برچسب‌زنی خواهد بود.



شکل ۴. گره ۱۴ برنده اولین مرحله انتشار برچسب بر اساس نمره شباهت ناهنجاری

دوباره همین روال را، برای گره‌های بدون برچسب تکرار می‌کنیم، با این تفاوت که الان گره ۱۴ برچسب آبی دارد. با چندین مرحله تکرار، در نهایت تمامی گره‌ها، مطابق شکل ۵ برچسب می‌خورند. بعد از این مرحله، وارد گام سوم یعنی ترکیب پیش‌اجتماع‌ها می‌شویم.



شکل ۵. برچسب‌های اولیه گره‌ها در مجموعه دیتاست دلفین

۳،۲. گام سوم: ترکیب پیش‌اجتماع‌ها بر اساس بهینه‌سازی معیار ماژولاریتی

رویکرد گام سوم بدین صورت است که پیش‌اجتماع‌ها را با هم ترکیب شده و معیار ماژولاریتی محاسبه می‌شود و تا جایی که معیار ماژولاریتی افزایش پیدا کند، این روند ادامه می‌یابد. هدف، به دست آوردن بهترین مقدار، برای معیار ماژولاریتی است.

ششمین همایش بین‌المللی افق‌های نوین در مهندسی برق، کامپیوتر و مکانیک

6th International Conference on the New Horizons in Electrical Engineering, Computer and Mechanical

www.mhconf.ir

ماژولاریتی، معیاری برای ارزیابی کیفیت خوشه‌ها در گراف است. این معیار به دلیل سادگی و کارایی، جزء معیارهای پرکاربرد در ارزیابی کیفیت خوشه‌ها است. متد لوین یک روش نسبتاً سریع برای پیدا کردن گروه‌ها در شبکه‌های بزرگ است. این روش با استفاده از روش‌های حریصانه بر روی ماژولاریتی، آن را بهینه کرده و به خوشه‌بندی راس‌های گراف می‌پردازد. این بهینه‌سازی در دو مرحله انجام می‌شود:

مرحله ۱- با بهینه‌سازی محلی، متد به دنبال گروه‌های کوچک می‌گردد.

مرحله ۲- سپس با ادغام گروه‌های کوچک که توانایی ایجاد گروه‌های بزرگ‌تر را دارند، خوشه‌بندی را ادامه می‌دهد. این مراحل مرتباً تکرار می‌شود تا مقدار بیشینه ماژولاریتی حاصل شود.

معیار ماژولاریتی در اصل، تفاضل بین تعداد یال‌ها در خوشه از تعداد یال‌های مورد نظر متناسب با تعداد گره‌های خوشه مطابق قانون توانی را محاسبه می‌کند و همواره در بازه ۰.۵- تا ۱ قرار دارد.

۴. آزمایشات و نتایج

در این بخش، به ارزیابی دقت و کارایی رویکرد معرفی شده برای تشخیص اجتماع در شبکه‌های پیچیده خواهیم پرداخت. این ارزیابی‌ها با استفاده از معیارهایی خواهد بود که در بخش بعد به تفصیل توضیح داده خواهد شد. آزمایشات و پیاده‌سازی‌ها در محیط متلب ۲۰۲۱ و بر روی سیستمی با مشخصات سیستم عامل ویندوز ۱۰، حافظه ۸ گیگا بایت و پردازنده Intel Core i5 انجام گرفته است.

۱.۴. معیارهای ارزیابی

در این پژوهش، برای مقایسه دقت و عملکرد رویکرد پیشنهادی، از معیارهای F-measure، نرخ صحت، ماژولاریتی و معیار NMI استفاده خواهیم کرد.

۱.۱.۴. محاسبه نرخ صحت

معیارهای نرخ صحت و F-measure، معیارها مبتنی بر ماتریس پیریشانی هستند. ماتریس پیریشانی یک ابزار مناسب برای تحلیل کارکرد مدل تمایزکننده است.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

شکل ۶. ماتریس پیریشانی دو کلاس با دو کلاس صفر و یک

که در آن TP و TN نشان‌دهنده زمانی است که مدل به درستی پیش‌بینی کرده و FP و FN هم نشان‌دهنده زمانی است که مدل به اشتباه دسته‌بندی شده است. نرخ صحت، نشان دهنده این است که چه قدر از داده‌ها برچسب درست خورده‌اند و F-measure از درصد داده‌های به درستی پیش‌بینی شده خبر می‌دهد و محاسبه آن نیازمند محاسبه نرخ فراخوانی است. این مقدار طبق فرمول (۳) محاسبه خواهند شد:

$$\text{نرخ صحت} = \frac{TP + TN}{TP + FP + FN} \quad (3)$$

۲.۱.۴. محاسبه ماژولاریتی

در سال ۲۰۰۴، نیومن-گیروان معیار ماژولاریتی را معرفی کرده‌اند. به طور کلی، اساس ماژولاریتی بر پیروی شبکه‌های پیچیده واقعی از قانون توانی استوار است و برابر با تعداد یال‌ها در اون اجتماع منهای تعداد یال مورد نظر مطابق قانون توانی است و در بازه ۰.۵- تا ۱ قرار دارد. معیار ماژولاریتی بر اساس فرمول (۴) محاسبه می‌شود.

$$Q = \frac{1}{2m} \sum_{ij} (A_{ij} - P_{ij}) \delta(C_i, C_j) \quad (4)$$

که در آن A ماتری مجاورتی گراف، m تعداد یالهای گراف، P ماتریس مورد انتظار از نظر تعداد یال‌های بین گره i و گره j و δ تابع بررسی در یک اجتماع بودن دو گره i و j است. اگر دو گره i و j در یک جامعه باشند، خروجی این تابع برابر با یک است و در غیر این صورت برابر با صفر است.

۲.۱.۴. محاسبه اطلاعات متقابل نرمال شده

معیار اطلاعات متقابل نرمال شده یا NMI ، تشابه آماری بین خوشه‌های ایجاد شده و برجسب‌های از پیش تعیین شده را اندازه می‌گیرد. هرچه کیفیت خوشه‌بندی بهتر باشد، مقدار آنروپی عددی کمتر و NMI عددی بیشتر خواهد بود و مطابق با فرمول (۵) محاسبه می‌شود.

$$NMI(x, y) = \frac{2I(x, y)}{H(x) + H(y)} \quad (5)$$

که در آن $I(x, y)$ اطلاعات مشترک دو اجتماع x و y و $H(x)$ و $H(y)$ آنروپی دو اجتماع x و y را محاسبه می‌کند.

۲.۴. نتایج آزمایشات

هدف از انجام آزمایش‌ها، بررسی و مقایسه عملکرد الگوریتم پیشنهادی از جنبه‌های مختلفی مانند، نرخ صحت؛ اطلاعات متقابل نرمال شده و زمان عملیات با الگوریتم تشخیص اجتماع بهبود یافته در منبع یک و روش مورد قبول و عمومیت یافته LPA است.

۱.۲.۴. بررسی اطلاعات متقابل نرمال شده

در جدول ۳ نتایج ارزیابی‌ها بر روی دیتاست‌های دنیای واقعی آورده شده و با روش معروف LPA و روش TS [۱] مقایسه شده است.

جدول ۳. ارزیابی و مقایسه روش پیشنهادی بر اساس معیار اطلاعات متقابل نرمال شده

نام دیتاست	روش پیشنهادی	الگوریتم TS [۱]	روش LPA
باشگاه کاراته زاکاری	۰/۴۴	۰/۴۲	۰/۵۱
دلفین‌ها	۰/۴۶	۰/۳۷	۰/۶۹
کتاب‌های سیاسی آمریکا	۰/۵۷	۰/۵۶	۰/۵۳
باشگاه‌های فوتبال	۰/۶۹	۰/۸۵	۰/۷۹

در سه دیتاست باشگاه کاراته، دلفین‌ها و کتاب‌های سیاسی آمریکا روش پیشنهادی ما، عملکرد بهتری نسبت به الگوریتم TS داشته است. در حالیکه در دیتاست فوتبال، الگوریتم LPA و TS نسبت به رویکرد پیشین عملکرد بهتری دارند.

۲.۲.۴. بررسی معیار ماژولاریتی

در جدول ۴ ارزیابی‌ها بر روی دیتاست‌های دنیای واقعی آورده شده و با روش معروف LPA و روش TS مقایسه شده است.

ششمین همایش بین‌المللی افق‌های نوین در مهندسی برق، کامپیوتر و مکانیک

6th International Conference on the New Horizons in Electrical Engineering, Computer and Mechanical

www.mhconf.ir

جدول ۴. ارزیابی و مقایسه روش پیشنهادی بر اساس معیار ماژولاریتی

نام دیتاست	روش پیشنهادی	الگوریتم TS [۳]	روش LPA
باشگاه کاراته زاکاری	۰/۴۰	۰/۳۸	۰/۳۴
دلفین‌ها	۰/۴۶	۰/۱۹	۰/۴۷
کتاب‌های سیاسی آمریکا	۰/۴۰	۰/۴۰	۰/۴۹
باشگاه‌های فوتبال	۰/۵۰	۰/۶۶	۰/۵۸

عقب بودن روش پیشنهادی در دیتاست فوتبال نسبت به روش LPA و روش TS در مورد معیار ماژولاریتی نیز صدق می‌کنند.

۳.۲.۴. بررسی و ارزیابی نرخ صحت

علاوه بر معیارهای ماژولاریتی و اطلاعات متقابل نرمال شده، در روش‌های عنوان شده برای تشخیص اجتماع، پیش‌بینی تعلق درست گره‌ها به اجتماع، نیز از اهمیت بالایی برخوردار است. بنابراین روش پیشنهادی و روش TS را از لحاظ نرخ صحت، مقایسه کردیم. لازم به ذکر است در ارزیابی این معیار به دلیل عدم همگرایی و تصادفی بودن نتایج نهایی روش LPA لحاظ نشده است.

جدول ۵. ارزیابی و مقایسه روش پیشنهادی بر اساس نرخ صحت

نام دیتاست	روش پیشنهادی	الگوریتم TS [۳]
باشگاه کاراته زاکاری	۰/۵۸	۰/۳۹
دلفین‌ها	۰/۶۷	۰/۳۲
کتاب‌های سیاسی آمریکا	۰/۷۲	۰/۶۲
باشگاه‌های فوتبال	۰/۳۸	۰/۲۵

در هر ۴ دیتاست مذکور، روش پیشنهادی از عملکرد بهتری نسبت به روش مقاله پایه برخوردار است.

۴.۲.۴. بررسی و ارزیابی سرعت عملیات

زمان اجرای الگوریتم، یکی از فاکتورهای مهم الگوریتم‌های تشخیص اجتماع است. هم‌چنان رشد سریع و روزافزون داده‌ها در دنیای امروز، اهمیت تحلیل داده‌ها در زمان کم‌تر را بیش‌تر نمایان می‌کند. بنابراین در جدول ۶ مدت زمان اجرای روش پیشنهادی، با روش TS و روش LPA مقایسه شده است.

جدول ۶. ارزیابی و مقایسه روش پیشنهادی بر اساس مدت زمان انجام عملیات (واحد ثانیه)

نام دیتاست	روش پیشنهادی	الگوریتم TS [۳]	روش LPA
باشگاه کاراته زاکاری	۱۱	۱۴/۳	۰/۰۶۱
دلفین‌ها	۱۷	۱۸/۷۸	۰/۰۹۲
کتاب‌های سیاسی آمریکا	۴۱/۳۳	۴۸/۲۴	۰/۱۱
باشگاه‌های فوتبال	۵۰/۳۲	۱۱۲/۹	۰/۱۲

روش LPA از سریع‌ترین الگوریتم‌های تشخیص اجتماع است اما این الگوریتم به دلیل تصادفی بودن و عدم همگرایی، چندان روش قابل اطمینانی نیست. در حالیکه روش پیشنهادی در کنار زمان پایین‌تر نسبت به الگوریتم TS، از صحت نرخ بالاتری نیز برخوردار است.

۵. نتیجه‌گیری

در این پژوهش برای اولین بار، تعریف گره‌های پراهمیت در شبکه‌های پیچیده، بر اساس گره‌های ناهنجار تعریف شد. یعنی گره‌هایی به عنوان گره مرکزی شناخته شدند که رفتار آن‌ها، از رفتار غالب گره‌های شبکه دور باشد. این گره‌های ناهنجار می‌توانند گره‌هایی متعلق به

یک سلبریتی؛ اینفلوئنسر یا یک کلاهبردار مالی باشد. روش پیشنهادی، از زمان اجرای کم‌تری نسبت به الگوریتم‌های هم‌تراز خود برخوردار است، در حالیکه نسبت به الگوریتم‌هایی مشهوری مانند LPA کندتر عمل می‌کند ولی همگرایی، نرخ صحت و ماژولاریتی بالاتر این روش باعث می‌شود تا این روش نسبت به روش‌های پیشین، قابل قبول‌تر باشد.

۶. منابع

- [1] حسینی، م. و ا. مه‌آبادی. روش توزیعی تشخیص انجمن در شبکه‌های اجتماعی بزرگ بر اساس انتشار برچسب ۱,۱,۲۳۲۲۴۳۴۷,۱۳۹۹,۸,۴,۱,۷ : ۲۰,۱۰۰۱,۱,۲۳۲۲۴۳۴۷,۱۳۹۹. ۱۳۹۹
- [2] صالحی، س.م.م. and ع.ا. پویان. انجمن‌یابی در شبکه‌های اجتماعی به کمک یادگیری عمیق. چهارمین کنفرانس پردازش سیگنال و سیستم‌های هوشمند. ۱۳۹۷
- [3] You, X., Y. Ma, and Z. Liu, A three-stage algorithm on community detection in social networks. Knowledge-Based Systems, 2020. 187: p. 104822.
- [4] S. Aghaalizadeh, S. T. Afshord, A. Bouyer, and B. Anari, "A three-stage algorithm for local community detection based on the high node importance ranking in social networks," Physica A: Statistical Mechanics and its Applications, vol. 563, p. 125420, 2021/02/01/ 2021.
- [5] Freeman, L., The Development of Social Network Analysis. 2004.
- [6] Moody, J. and D. White, White, D.: Structural Cohesion and Embeddedness: A Hierarchical Concept of Social Groups. American Sociological Review 68, 103-127. American Sociological Review, 2003. 68: p. 103-127.
- [7] Fortunato, S., Community detection in graphs. Physics Reports, 2010. 486(3): p. 75-174.3. You, X., Y. Ma, and Z. Liu, A three-stage algorithm on community detection in social
- [8] Aynaud, T. and J.-L. Guillaume. Multi-Step Community Detection and Hierarchical Time Segmentation in Evolving Networks. in Fifth SNA-KDD Workshop Social Network Mining and Analysis, in conjunction with the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2011). 2011. San Diego, CA, United States.
- [9] Scott, J., Social Network Analysis. Sociology, 1988. 22(1): p. 109-127.
- [10] Wasserman, S. and K. Faust, Social Network Analysis: Methods and Applications. Structural Analysis in the Social Sciences. 1994, Cambridge: Cambridge University Press.
- [11] Ravasz, E. and A.-L. Barabási, Hierarchical organization in complex networks. Physical Review E, 2003. 67(2): p. 026112.
- [12] Boccaletti, S., et al., Complex networks: Structure and dynamics. Physics Reports, 2006. 424(4): p. 175-308.
- [13] Ostroumova Prokhorenkova, L. and E. Samosvat. Global Clustering Coefficient in Scale-Free Networks. 2014. Cham: Springer International Publishing.
- [14] Csányi, G. and B. Szendrői, Structure of a large social network. Physical Review E, 2004. 69(3): p. 036131.
- [15] Jaccard, P., Étude comparative de la distribution florale dans une portion des Alpes et des Jura. Bull Soc Vaudoise Sci Nat, 1901. 37: p. 547-579.
- [16] T. Sørensen et al., "A method of establishing groups of equal amplitude in plant sociology based on similarity of species content and its application to analyses of the vegetation on Danish commons," 1948.
- [17] J. Scripps, P. Tan, and A. Esfahanian, "Exploration of Link Structure and Community-Based Node Roles in Network Analysis," in Seventh IEEE International Conference on Data Mining (ICDM 2007), 2007, pp. 649-654.
- [18] M. Newman and M. Girvan, "Finding and Evaluating Community Structure in Networks," Physical review. E, Statistical, nonlinear, and soft matter physics, vol. 69, p. 026113, 03/01 2004.
- [19] N. Raghavan, R. Albert, and S. Kumara, "Near Linear Time Algorithm to Detect Community Structures in Large-Scale Networks," Physical review. E, Statistical, nonlinear, and soft matter physics, vol. 76, p. 036106, 10/01 2007.
- [20] A. Grover and J. Leskovec, "node2vec: Scalable Feature Learning for Networks," (in eng), Kdd, vol. 2016, pp. 855-864, Aug 2016.
- [21] M. E. J. Newman, "Detecting community structure in networks," The European Physical Journal B, vol. 38, no. 2, pp. 321-330, 2004/03/01 2004.
- [22] M. E. J. Newman, "The Structure and Function of Complex Networks," Computer Physics Communications, vol. 147, pp. 40-45, 03/15 2003.
- [23] C. Ma and J. Wu, Data Clustering: Theory, Algorithms, and Applications. 2007.
- [24] B. W. Kernighan and S. Lin, "An efficient heuristic procedure for partitioning graphs," The Bell System Technical Journal, vol. 49, no. 2, pp. 291-307, 1970.
- [25] S. Dutt, "New faster Kernighan-Lin-type graph-partitioning algorithms," in Proceedings of 1993 International Conference on Computer Aided Design (ICCAD), 1993, pp. 370-377.
- [26] M. Chen, K. Kuzmin, and B. K. Szymanski, "Community Detection via Maximization of Modularity and Its Variants," IEEE Transactions on Computational Social Systems, vol. 1, no. 1, pp. 46-65, 2014.
- [27] J. Xie and B. K. Szymanski, "Community detection using a neighborhood strength driven Label Propagation Algorithm," in 2011 IEEE Network Science Workshop, 2011, pp. 188-195.
- [28] J. Cao, D. Jin, L. Yang, and J. Dang, "Incorporating network structure with node contents for community detection on large networks using deep learning," Neurocomputing, vol. 297, 02/01 2018.

- [29] A. Lancichinetti, S. Fortunato, and F. Radicchi, "Benchmark graphs for testing community detection algorithms," *Physical review E*, vol. 78, no. 4, p. 046110, 2008.
- [30] W. W. Zachary, "An information flow model for conflict and fission in small groups," *Journal of anthropological research*, vol. 33, no. 4, pp. 452-473, 1977.
- [31] D. Lusseau, K. Schneider, O. J. Boisseau, P. Haase, E. Sloaten, and S. M. Dawson, "The bottlenose dolphin community of Doubtful Sound features a large proportion of long-lasting associations," *Behavioral Ecology and Sociobiology*, vol. 54, no. 4, pp. 396-405, 2003.
- [32] M. E. Newman, "Modularity and community structure in networks," *Proceedings of the national academy of sciences*, vol. 103, no. 23, pp. 8577-8582, 2006.
- [33] M. Girvan and M. E. Newman, "Community structure in social and biological networks," *Proceedings of the national academy of sciences*, vol. 99, no. 12, pp. 7821-7826, 2002.
- [34] R. Guimera, L. Danon, A. Diaz-Guilera, F. Giralt, and A. Arenas, "Self-similar community structure in a network of human interactions," *Physical review E*, vol. 68, no. 6, p. 065103, 2003.
- [35] M. E. Newman, "Finding community structure in networks using the eigenvectors of matrices," *Physical review E*, vol. 74, no. 3, p. 036104, 2006.
- [36] D. J. Watts and S. H. Strogatz, "Collective dynamics of 'small-world' networks," *nature*, vol. 393, no. 6684, p. 440, 1998.
- [37] J. Leskovec, J. Kleinberg, and C. Faloutsos, "Graph evolution: Densification and shrinking diameters," *ACM Transactions on Knowledge Discovery from Data (TKDD)*, vol. 1, no. 1, p. 2, 2007.
- [38] J. Duch and A. Arenas, "Community detection in complex networks using extremal optimization," *Physical review E*, vol. 72, no. 2, p. 027104, 2005.
- [39] M. Boguná, R. Pastor-Satorras, A. Díaz-Guilera, and A. Arenas, "Models of social networks based on social distance attachment," *Physical review E*, vol. 70, no. 5, p. 056122, 2004.
- [40] B. Rozemberczki, C. Allen, and R. Sarkar, "Multi-scale Attributed Node Embedding," *arXiv preprint arXiv:1909.13021*, 2019.
- [41] M. E. Newman, "Fast algorithm for detecting community structure in networks," *Physical review E*, vol. 69, no. 6, p. 066133, 2004.
- [42] J. Leskovec, K. J. Lang, A. Dasgupta, and M. W. Mahoney, "Community structure in large networks: Natural cluster sizes and the absence of large well-defined clusters," *Internet Mathematics*, vol. 6, no. 1, pp. 29-123, 2009.
- [43] M. E. Newman, "The structure of scientific collaboration networks," *Proceedings of the national academy of sciences*, vol. 98, no. 2, pp. 404-409, 2001.
- [44] L. Akoglu, M. McGlohon, and C. Faloutsos, "oddball: Spotting Anomalies in Weighted Graphs," in *Advances in Knowledge Discovery and Data Mining*, Berlin, Heidelberg, 2010, pp. 410-421: Springer Berlin Heidelberg.