

ارائه الگوریتمی جدید برای تشخیص اجتماع با

استفاده از یادگیری تقویتی چندعاملی

میرمحمد علیپور*^۱ و محسن عبدالحسینزاده^۲

^۱ گروه مهندسی کامپیوتر، دانشگاه بناب، بناب، ایران

^۲ گروه ریاضی، دانشکده علوم پایه، دانشگاه بناب، بناب، ایران

چکیده

مسئله تشخیص اجتماع، یکی از مسائل چالش‌برانگیز بهینه‌سازی است که شامل جستجو برای اجتماعاتی است که به یک شبکه یا گراف تعلق دارند و گره‌های عضو هر یک از آن‌ها دارای ویژگی‌های مشترک هستند، که تشخیص ویژگی‌های جدید یا روابط خاص در شبکه را ممکن می‌سازند. اگرچه برای مسئله تشخیص اجتماع الگوریتم‌های متعددی ارائه شده است، اما بسیاری از آن‌ها در مواجهه با شبکه‌های با مقیاس بزرگ قابل‌استفاده نیستند و از هزینه محاسباتی بسیار بالایی برخوردارند. در این مقاله، الگوریتم جدیدی مبتنی بر یادگیری تقویتی چندعاملی برای تشخیص اجتماع در شبکه‌های پیچیده ارائه خواهیم کرد که در آن، هر عامل یک موجودیت مستقل با پارامترهای یادگیری متفاوت هستند و بر اساس همکاری بین عامل‌ها، الگوریتم پیشنهادی به صورت تکرارشونده و بر اساس سازوکار یادگیری تقویتی، به جستجوی اجتماعات بهینه می‌پردازد. کارایی الگوریتم پیشنهادی را بر روی چهار شبکه واقعی و تعدادی شبکه مصنوعی ارزیابی شده است، و با تعدادی از الگوریتم‌های مشهور در این زمینه مقایسه می‌کنیم. بر اساس ارزیابی انجام‌گرفته، الگوریتم پیشنهادی علاوه بر دقت بالا در تشخیص اجتماع، از سرعت و پایداری مناسبی برخوردار است و قابلیت رقابت و حتی غلبه بر الگوریتم‌های مطرح در زمینه تشخیص اجتماع را نیز داشته و نتایج الگوریتم پیشنهادی بر اساس معیارهای Q-ماجولاریتی و NMI متوسط بر روی شبکه‌های واقعی و مصنوعی به ترتیب ۱۲/۳۳٪، ۹/۸۵٪ و بیش از ۲۱٪ بهتر از الگوریتم‌های مورد مقایسه است.

واژگان کلیدی: شبکه‌های پیچیده، تشخیص اجتماع، سامانه‌های چندعاملی، یادگیری تقویتی، Q-ماجولاریتی.

A Multiagent Reinforcement Learning algorithm to solve the Community Detection Problem

Mir Mohammad Alipour*¹ & Mohsen Abdolhosseinzadeh²

¹ Department of Computer Engineering, University of Bonab, Bonab, Iran

² Department of Mathematics, Faculty of Basic Science, University of Bonab, Bonab, Iran

Abstract

Recent researches show that diverse systems in many different areas can be represented as complex networks. Examples of these include the Internet, social networks and so on. In each case, the system can be modeled as a complex and very large network consisting of a large number of entities and associations between them. Most of these networks are generally sparse in global yet dense in local. They have vertices in a group structure and the vertices within a group have higher density of edges while vertices among groups have lower density of edges. Such a structure is called community and is one of the important features of the network and is able to reveal many hidden characteristics of the networks. Today, community detection is used to improve the efficiency of search engines and discovery of terrorist organizations on the World Wide Web.

Community detection is a challenging NP-hard optimization problem that consists of searching for communities. It is assumed that the nodes of the same community share some properties that enable the detection of new characteristics or functional relationships in a network. Although there are many

* Corresponding author

* نویسنده عهده‌دار مکاتبات

سال ۱۴۰۱ شماره ۱ پیاپی ۵۱

• تاریخ ارسال مقاله: ۱۳۹۸/۷/۲۳ • تاریخ پذیرش: ۱۴۰۰/۹/۱۵ • تاریخ انتشار: ۱۴۰۱/۰۳/۳۱ • نوع مطالعه: پژوهشی



فصلنامه علمی



۱۰۱

algorithms developed for community detection, most of them are unsuitable when dealing with large networks due to their computational cost.

Nowadays, multiagent systems have been used to solve different problems, such as constraint satisfaction problems and combinatorial optimization problems with satisfactory results. In this paper, a new multiagent reinforcement learning algorithm is proposed for community detection in complex networks. Each agent in the multiagent system is an autonomous entity with different learning parameters. Based on the cooperation among the learning agents and updating the action probabilities of each agent, the algorithm interactively will identify a set of communities in the input network that are more densely connected than other communities. In other words, some independent agents interactively attempt to identify communities and evaluate the quality of the communities found at each stage by the normalized cut as objective function; then, the probability vectors of the agents are updated based on the results of the evaluation. If the quality of the community found by an agent in each of the stages is better than all the results produced so far, then it is referred to as the successful agent and the other agents will update their probability vectors based on the result of the successful agent.

In the experiments, the performance of the proposed algorithm is validated on four real-world benchmark networks: the Karate club network, Dolphins network, Political books network and College football network, and synthetic LFR benchmark graphs with scales of 1000 and 5000 nodes. LFR networks are suitable for systematically measuring the property of an algorithm.

Experimental results show that proposed approach has a good performance and is able to find suitable communities in large and small scale networks and is capable of detecting the community in complex networks in terms of speed, precision and stability. Moreover, according to the systematic comparison of the results obtained by the proposed algorithm with four state-of-the-art community detection algorithms, our algorithm outperforms these algorithms in terms of modularity and NMI; also, it can detect communities in small and large scale networks with high speed, accuracy, and stability, where it is capable of managing large-scale networks up to 5000 nodes.

Keywords: Complex networks, Community detection, Multiagent systems, Reinforcement learning, Modularity Q.

پنهان شبکه‌های داده‌شده را نیز آشکار سازد. برای مثال، اجتماعات مربوط به موضوعات موردعلاقه در وب جهانی، نمونه‌ای در این زمینه است. در شبکه‌های اجتماعی افراد عضو یک اجتماع متمایل به داشتن ویژگی‌های مشترکی هستند. امروزه از تشخیص اجتماع برای بهبود کارایی موتورهای جستجو و کشف سازمان‌های تروریستی در وب جهانی استفاده می‌شود؛ از این رو، شناسایی اجتماع نه تنها یک گام اساسی برای کشف آنچه موجب کنار یکدیگر قرارگرفتن موجودیت‌ها است، بلکه برای درک کلی ویژگی‌های کارکردی و ساختاری یک شبکه بزرگ نیز مؤثر است [5]. تشخیص اجتماع یک مسأله NP-hard است، که روش‌های بهینه‌سازی مرسوم قادر به حل مؤثر آن نیستند [6]؛ لذا پژوهش‌های گسترده‌ای بر روی مسأله تشخیص اجتماع انجام و الگوریتم‌های اکتشافی و فرااکتشافی متنوعی برای حل آن ارائه شده است.

امروزه برای حل مؤثر مسائل بهینه‌سازی ترکیبی و کسب نتایج رضایت‌بخش، از سامانه‌های چندعاملی استفاده می‌شود [7-11]. در این مقاله الگوریتمی جدید مبتنی بر یادگیری تقویتی چندعاملی برای شناسایی اجتماع در شبکه‌های پیچیده ارائه خواهیم کرد که در آن تعدادی عامل مستقل برای یافتن اجتماعات مناسب با یکدیگر همکاری کرده‌اند و به‌طور تکرارشونده اجتماعات

۱- مقدمه

پژوهش‌های اخیر بیانگر این واقعیت است که می‌توان سامانه‌های متنوع موجود در بسیاری حوزه‌های مختلف را به‌صورت شبکه‌های پیچیده نمایش داد [1-3]. مثال‌هایی در این زمینه شامل اینترنت، وب گسترده جهانی، شبکه‌های اجتماعی و غیره هستند. در هر یک از موارد یادشده، می‌توان سامانه را به‌صورت یک شبکه پیچیده و بسیار بزرگ مدل‌سازی کرد که از تعداد کلانی از موجودیت‌ها و ارتباطات بین آن‌ها تشکیل شده است. به‌عنوان مثال اتصالات فیزیکی بین مسیریاب‌ها در سطح اینترنت، ابر پیوندهای موجود در صفحات وب، دوستی‌های بین افراد و مراجع بکار رفته در مقالات، از آن جمله هستند.

این شبکه‌ها اغلب در مقیاس سراسری به‌صورت پراکنده بوده ولی در مقیاس محلی متراکم هستند. آن‌ها دارای رئوس با ساختار گروهی بوده و یال‌های بین رئوس متعلق به یک گروه نسبت به یال‌های بین رئوس متعلق به گروه‌های دیگر از تراکم بیشتری برخوردارند. به‌بیان دیگر، تراکم یال‌های بین رئوس متعلق به یک گروه، بیشتر از تراکم یال‌های بین رئوس متعلق به گروه‌های متفاوت است [4]. چنین ساختاری اجتماع نامیده می‌شود و یکی از ویژگی مهم شبکه بوده و قادر است بسیاری از ویژگی‌های

شامل دو دسته تقسیم‌کننده^۳ و تجمعی^۴ هستند و به‌صورت سلسله مراتبی و تدریجی اجتماعات شکل می‌گیرند. افراد مختلفی الگوریتم‌های سلسله‌مراتبی بهبود داده‌اند، که با استفاده از معیارهایی جهت انتخاب پارتیشن مناسب یا مجموعه‌ای مناسب از پارتیشن‌ها که معیارهای خاصی مانند تعداد اجتماعات موردنظر، حداکثر (یا حداقل) تعداد رئوس در هر اجتماع را برآورد کرده و تابع هدف مشخصی را بهینه‌سازی می‌کنند [15]. روش‌های تقسیم‌کننده در تلاش‌اند تا ابتدا یال‌هایی که رئوس اجتماعات مختلف اتصال‌دهنده به یکدیگر را یافته و سپس به‌طور تکرار شونده آن‌ها را حذف کنند تا در نهایت اجتماعات از هم جدا شوند.

روش‌های تجمعی از استراتژی پایین به بالا جهت یافتن اجتماعات بهره می‌برند. به‌طور کلی، در این راه‌کارها، از پارتیشن‌های تک‌عضوی (یک رأس در هر پارتیشن) شروع شده و تا زمانی که یک اجتماع منفرد شامل تمام رئوس شبکه ورودی ایجاد شود، به‌طور مکرر فرآیند تقسیم‌بندی رئوس ادامه می‌یابد [12]. اغلب الگوریتم‌های تجمعی، بهترین پارتیشنی را انتخاب می‌کنند که تابع هدف کیفیت خاصی را به بیشینه می‌رساند.

یکی از پرکاربردترین توابع کیفیت شناخته‌شده، معیار Q-ماجولاریتی^۵ است که توسط نیومن و همکاران پیشنهاد شده است [12]. کلوست و همکاران با استفاده از معیار ماجولاریتی، روش بهینه‌سازی ماجولاریتی حریصانه‌ای را ارائه کرده‌اند که از یک مجموعه رئوس مجزا شروع شده و سپس جفت رأس به‌طور تکراری به هم متصل می‌شوند تا به حداکثر مقدار ممکن ماجولاریتی در هر مرحله برسد. اگرچه استفاده از این معیار نتایج امیدوارکننده برای شناسایی اجتماعات تولید می‌کند؛ اما دارای محدودیت‌هایی از قبیل محدودیت توان تفکیک وجود دارد. برای مثال در بدترین حالت، الگوریتم‌های بهینه‌سازی پیمان‌های در مواجهه با شبکه‌ای که دارای چندین گروه هستند و گروه‌ها به‌وسیله یک یال به یکدیگر متصل شده‌اند، شکست می‌خورند [14].

دوتی و مونز روش خوشه‌بندی سلسله‌مراتبی را ارائه کرده‌اند که در آن از بردارهای ویژه ماتریس لاپلاسن گراف استفاده شده است و شباهت بین رئوس گراف را اندازه‌گیری می‌کنند. پیچیدگی زمانی محاسبه تمامی

موجود در شبکه را تشخیص می‌دهند، و پس از ارزیابی کیفیت اجتماعات یافته شده، بردارهای احتمال اقدام هر عامل به‌روزرسانی می‌شود.

برای ارزیابی کارایی راه‌کار پیشنهادی، در آزمایش‌های تجربی از دو نوع مختلف از شبکه‌های محک^۱ استفاده کرده‌ایم که شامل شبکه‌های مشهور دنیای-واقعی و شبکه‌های مصنوعی مقیاس بزرگ LFR هستند. نتایج به‌دست‌آمده بیان‌گر توانایی راه‌کار پیشنهادی برای یافتن اجتماعات مناسب در شبکه‌های با مقیاس کوچک و بزرگ است، و قادر به تشخیص اجتماع موجود در شبکه‌های پیچیده با سرعت، دقت و پایداری بالا است. همچنین، بر اساس مقایسه سیستماتیک نتایج به‌دست‌آمده به‌وسیله الگوریتم پیشنهادی و تعدادی از الگوریتم‌های مطرح در زمینه تشخیص اجتماع، می‌توان ادعا کرد که راه‌کار پیشنهادی بر اساس دقت و سرعت، توانایی غلبه بر آن‌ها را دارد.

ادامه مقاله حاضر به شرح زیر سازمان‌دهی شده‌است: مرور و بررسی کارهای مرتبط در زمینه تشخیص اجتماع، در بخش ۲ انجام می‌گیرد. در بخش ۳ معرفی کوتاهی بر یادگیری تقویتی چندعاملی ارائه شده است. جزئیات مربوط به راه‌کار پیشنهادی در بخش ۴ توضیح داده خواهد شد. آزمایش‌های تجربی بر روی شبکه‌های محک دنیای-واقعی و شبکه‌های مصنوعی مقیاس بزرگ LFR در بخش ۵ انجام خواهد گرفت، و در نهایت بخش ۶ به جمع‌بندی و نتیجه‌گیری مقاله می‌پردازد.

۲- کارهای مرتبط

تشخیص اجتماع در شبکه‌های پیچیده به دلیل کاربردهای گسترده آن مورد توجه محققین فراوانی قرار گرفته است [12-14]. فورچوناتو مروری جامع بر روش‌ها و کاربردهای مسئله تشخیص اجتماع ارائه کرده است [15]. وی روش‌های تشخیص اجتماع را به پنج دسته: الگوریتم‌های مرسوم، الگوریتم‌های سلسله‌مراتبی، الگوریتم‌های برمبنای ماجولاریتی، الگوریتم‌های طیفی^۲ و الگوریتم‌های پویا طبقه‌بندی کرده است. در میان همه انواع روش‌های تشخیص اجتماع، تکنیک‌های سلسله‌مراتبی نسبت به سایر روش‌ها به‌طور گسترده‌تری مورد استفاده قرار گرفته‌اند. الگوریتم‌های خوشه‌بندی سلسله‌مراتبی

³ divisive

⁴ agglomerative

⁵ modularity Q

¹ benchmark

² spectral

بردارهای ویژه برای ماتریس‌های پراکنده برابر $O(n^3)$ است و با توجه به اینکه نیازی به تعیین اندازه یا تعداد اجتماعات از قبل نداریم، در نتیجه، روش بالا از زمان توقف فرآیند تجمعی جهت بهترین تقسیم‌بندی شبکه، اطلاعی ندارد [16].

گیروان و نیومن با استفاده از برش مکرر یال‌های دارای بزرگ‌ترین مقدار بینابینی¹ روش تقسیم‌کننده‌ای را معرفی کرده‌اند که می‌تواند تقسیم‌بندی بهینه‌ای از شبکه را با پیچیدگی زمانی $O(n^3)$ ، نسبت به شبکه بهینه ایجاد کند [17, 18]. رادیچی روشی مشابهی را با استفاده از ضریب خوشه‌بندی-یال² به‌عنوان معیاری جدید با پیچیدگی زمانی کوچک‌تر $O(n^2)$ ارائه کرده است [19]. برای بهبود بیشتر کارایی، کلوس، نیومن و مور الگوریتم خوشه‌بندی سریع با پیچیدگی زمانی $O(n \log^2 n)$ بر روی گراف‌های پراکنده را ارائه کرده‌اند که به‌صورت مکرر جفت‌گره‌ها را جهت ایجاد ΔQ بیشینه، تا زمان منفی شدن مقدار آن، درهم ادغام می‌کند [13].

نوع دیگری از راه‌کارهای مورد استفاده برای حل مسأله تشخیص اجتماع، الگوریتم‌های مبتنی بر گام تصادفی³ هستند. در این الگوریتم‌ها، علاوه بر مدنظر قرار دادن ساختار توپولوژیکی شبکه، ویژگی‌های همسایگی محلی رؤس نیز در نظر گرفته می‌شود؛ بنابراین می‌تواند برای تشخیص اجتماع در برخی از انواع شبکه‌های پیچیده مناسب باشد. هاگن و همکاران از این راه‌کار برای شناسایی خوشه‌ها در طراحی مدارات مجتمع VLSI استفاده کرده‌اند [20]. مئو و همکاران یک روش خوشه‌بندی جدید برای شبکه‌های پیچیده به نام CONCLUDE ارائه کرده‌اند که مقیاس‌پذیری الگوریتم‌های محلی و دقت راه‌کارهای جهانی را ترکیب می‌کند [21]. کائو و همکاران از برنامه‌ریزی چندهدفه برای بهینه‌سازی شبکه‌ای از تولیدکنندگان و مصرف‌کنندگان انرژی استفاده کردند؛ آن‌ها همچنین یک سیستم چندعاملی جزئی برای تشخیص اجتماع تولیدکنندگان و مصرف‌کنندگان بهره‌برده‌اند [22]. هان و همکاران شبکه‌ای را در نظر می‌گیرند که ارتباطات به‌طور صریح بیان نشده است؛ آن‌ها از یک چارچوب چهار فازی برای شباهت‌یابی و ارزیابی ساختار شبکه و ارتباطات استفاده کرده‌اند [23]. فنگ و یانگ یک سامانه زمان پیوسته را در نظر گرفتند، و به‌دنبال تشخیص اجتماع در

یک شبکه بزرگ با تقسیم آن به چندین شبکه کوچک بوده‌اند؛ الگوریتم آن‌ها بر مبنای میزان عملکرد در شبکه‌های کوچک‌تر و به‌صورت هم‌گرایی متوسط جمعی ارزیابی می‌شود [24].

پونز و لاتایی الگوریتم خوشه‌بندی دیگری را با استفاده از روش گام تصادفی برای ارزیابی شباهت بین رؤس پیشنهاد کرده‌اند [25]. روش پیشنهادی از شبکه‌های پیمانه‌ای برای تعیین زمان توقف فرآیند تجمعی استفاده می‌کند و دارای پیچیدگی زمانی $O(n^2 \log n)$ است. رونجوده و نوسینف یک روش تقسیم شونده با به‌کارگیری مرکزیت یال بر مبنای گام تصادفی ارائه کرده‌اند، که ابتدا یال‌های متصل به یک رأس برگ حذف می‌شوند و سپس یال‌های به شکل پل ارتباطی بین اجتماعات را یافته و آن‌ها را از بین می‌برد [26].

علاوه‌براین، چن-دین روش اکتشافی و فرا اکتشافی برای حل این مسأله ارائه شده است. ژو و همکاران الگوریتمی ممتیک⁴ برای تقویت استحکام شبکه‌های بدون-مقیاس⁵ در برابر حملات مخرب ارائه کرده‌اند [27]. بو و همکاران یک الگوریتم ژنتیک برای پارتیشن‌بندی گراف با یک مرحله پیش‌پردازش الگو برای بهبود قابلیت جستجوی فضایی الگوریتم ژنتیک پیشنهاد داده‌اند [28]. تاسگین و همکاران از الگوریتم ژنتیک مبتنی بر ماجولاریتی برای تشخیص اجتماع استفاده کرده‌اند [29]. پیروتی الگوریتم ژنتیکی جهت تشخیص اجتماع با نام GA-Net ارائه کرده است که بر اساس نمایش همسایگی مکانی⁶ و عملگر ترکیب یکنواخت بوده و هنگامی که فقط همبستگی واقعی گره‌ها در نظر گرفته شود، در کاهش تعداد جستجوی غیرمجاز مؤثر است [30]. گوگ و همکاران الگوریتم تکاملی مشارکتی⁷ ارائه کرده‌اند که مبتنی بر مکانیزم به اشتراک‌گذاری اطلاعات بین افراد در جمعیت است [31]. گونگ و همکاران الگوریتمی ممتیک به نام Meme-Net را ارائه کرده‌اند که از بهینه‌سازی تراکم ماجولاریتی برای تشخیص اجتماع استفاده می‌کند [32].

لیو و همکاران روش نمایشی⁸ را طراحی کرده‌اند که می‌تواند اجتماعات مجزا و دارای همپوشانی را به‌طور هم‌زمان نمایش دهد. آن‌ها همچنین الگوریتم تکاملی چندمنظوره جهت حل مسأله تشخیص اجتماع ارائه کرده‌اند [33]. لیو و موراتا یک تحلیل مقایسه‌ای از الگوریتم‌های تکاملی و ممتیک برای تشخیص اجتماع در

⁴ memetic

⁵ scale-free

⁶ locus-based adjacency

⁷ collaborative

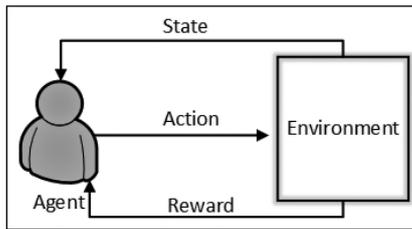
⁸ representation

¹ betweenness

² edge-clustering

³ random walk

اقدامی را برمی‌گزیند که منجر به انتقال محیط به وضعیتی جدید می‌شود. کیفیت انتقال وضعیت محیط به وسیله سیگنالی عددی به عامل اعلام می‌شود که در شکل (۱) نشان داده شده است.



(شکل-۱): تعامل عامل با محیط در یادگیری تقویتی.
(Figure-1): Agent-environment interaction in reinforcement learning.

وظیفه عامل پیشینه‌سازی پاداش کلی دریافتی در طول دوره یادگیری است [42]. عامل می‌تواند با استفاده از آزمون و خطای سیستماتیک در طی زمان و به‌کارگیری الگوریتم‌های یادگیری متعدد موجود، به این هدف نائل شود [43]. Q-یادگیری^۴ یکی از الگوریتم‌های یادگیری یادشده است که نوعی الگوریتم یادگیری تفاوت زمانی^۵ است، و به‌صورت تدریجی اقدام به ایجاد اطلاعاتی در مورد بهترین اقدام قابل انجام در هر وضعیت ممکن می‌کند. برای این منظور باید سیاستی را که منجر به پیشینه‌سازی برخی از معیارهای طولانی‌مدت می‌شود، پیدا کرد. سیاست، چگونگی رفتار عامل یادگیر را در هر زمان داده‌شده تعریف می‌کند، و در واقع نگاشتی از وضعیت‌های محیط درک شده به اقدام‌های قابل انجام است. اقدام قابل انجام وابسته به Q-مقادیر^۶ است و $Q(s, \alpha)$ میزان مطلوبیت اقدام α در موقعیت s را نشان می‌دهد؛ بنابراین فرآیند یادگیری شامل به‌روزرسانی پیوسته مقادیر بالا تا رهنمون عامل به انتخاب بهترین اقدام بر اساس این مقادیر است [42].

در حالت کلی، برای انتخاب اقدام در RL، روش‌های متعددی وجود دارد که روش انتخاب اقدام رایج سافتمکس^۷ یکی از آنها است. در این روش، ابتدا به هر یک از اقدام‌های موجود در فهرست اقدام‌های یک عامل، وزنی بر اساس رابطه (۱) اختصاص می‌یابد و سپس یکی از اقدام‌ها با در نظر گرفتن وزن واگذار شده به آن به‌صورت تصادفی انتخاب می‌شود، به طوری که احتمال انتخاب اقدام‌های با مقدار $P_i(\alpha|s)$ بیشتر، بالاتر خواهد بود.

$$P_i(\alpha|s) = \frac{Q(s, \alpha)}{\sum_{\hat{\alpha} \neq \alpha} Q(s, \hat{\alpha})} \quad (1)$$

⁴ Q-learning

⁵ temporal difference

⁶ Q-values

⁷ softmax

شبکه‌های اجتماعی ثبت‌نام‌شده ارائه کرده و الگوریتم تکاملی چندمنظوره برای تشخیص اجتماع در این شبکه‌ها ارائه کرده‌اند که مبتنی بر شباهت و نمایش ترکیبی مستقیم و غیرمستقیم بوده و جهت شناسایی اجتماعات مجزا و دارای همپوشانی به‌کار می‌رود [34]. سایر الگوریتم‌های جالب عبارت‌اند از روش بهینه‌سازی خارجی ارائه‌شده توسط دوچ و ارناس با پیچیدگی زمانی $O(n^2 \log n)$ [35]. الگوریتم افزایشی مبتنی بر نیرو ارائه‌شده توسط یانگ و لیو که بر یافتن ساختارهای اجتماعی در یک شبکه پویا متمرکز است [36].

گونش و بینگول یک الگوریتم تشخیص اجتماع مبتنی بر عامل تصادفی ارائه کرده‌اند که با وادار کردن عامل‌ها به انجام حرکات مغرضانه به روشی هوشمند و سپس با به‌کارگیری اطلاعات جمع‌آوری‌شده از پیمایش عامل‌های بالا در شبکه، ساختار شبکه آشکار می‌شود. در روش فوق از ماجولاریتی شبکه برای تعیین تعداد اجتماعات استفاده می‌شود [37]. لی و همکاران الگوریتمی به نام MAGA-Net ارائه کردند که نوعی الگوریتم ژنتیک چندعاملی برای بهینه‌سازی ماجولاریتی است [38]. این الگوریتم به لحاظ دقت و پایداری قادر است بر هر دو الگوریتم GA-NET و Meme-Net غلبه کند. هوانگ و همکاران یک الگوریتم غیرمتمرکز چندعاملی ارائه کرده‌اند که در آن تعدادی از عامل‌های مستقل به شکل گروهی فعالیت می‌کنند و به کاوش شبکه به‌وسیله استراتژی خودتجمعی^۱ می‌پردازد [39].

همه الگوریتم‌های مذکور راه‌کارهای موفق برای تشخیص اجتماع از دیدگاه‌های مختلف هستند. با این حال، شبکه‌های پیچیده واقعی به‌طور معمول گراف‌های پراکنده بزرگ با نواحی شامل گروه‌های هم‌پوشان هستند [40]. در نتیجه، هر یک از الگوریتم‌های ذکر شده دارای نقاط قوت و ضعف خاص خود بوده‌اند، و نتایج به‌دست‌آمده توسط آنها نسبت به توپولوژی شبکه‌های ورودی حساس هستند.

۳- یادگیری تقویتی و عامل یادگیرنده

یادگیری تقویتی^۲ که به اختصار RL نامیده می‌شود، یکی از روش‌های هوش مصنوعی است که در آن عامل واقع در یک محیط، اقدام‌هایی^۳ را انجام می‌دهد و در نتیجه پاداش عددی از محیط دریافت می‌کند [41]. در این روش، عامل در هر گام زمانی وضعیت کامل محیط را درک می‌کند و

¹ self-aggregation

² Reinforcement Learning (RL)

³ action



که در آن، احتمال انتخاب اقدام α توسط عامل RA_i در موقعیت s است، $S = \{1, 2, \dots, n\}$ مجموعه موقعیت‌هایی که هر عامل می‌تواند در آن‌ها قرار گیرد و در این مسأله درواقع مجموعه S متناظر با مجموعه رئوس گراف ورودی (V) است و $\hat{\alpha}$ بر سایر اقدام‌های این عامل در موقعیت s ، به‌جز اقدام α دلالت دارد.

با توانایی یادگیری آنلاین توسط عامل‌ها، کارایی عامل‌ها و کل سامانه چندعاملی (MAS) افزایش می‌یابد، و یادگیری تقویتی چندعاملی^۲ (MARL) نامیده می‌شود [44]. در محیط‌های پیچیده امکان طراحی عامل‌هایی که نیازهای رفتار مناسب از ابتدا در آن‌ها گنجانده شده باشد، مشکل و یا حتی غیرممکن است؛ به‌خصوص در محیط‌هایی که با گذشت زمان در حال تغییر هستند، رفتار از پیش تعیین‌شده ممکن است نتیجه نامناسبی داشته باشد [45، 46]. در چنین شرایطی، چندین عامل یادگیری تقویتی در یک محیط قرار می‌گیرند و در مورد اقدام خود در تصمیم گرفته و به‌وسیله تعامل با محیط پویا یاد می‌گیرند. بدیهی است که اقدام هر عامل تأثیری بر روی محیط می‌گذارد و در نتیجه اقدام یک عامل با توجه به اقدام سایر عامل‌ها می‌تواند پیامدهای متفاوتی داشته باشد. پس از تولید نتیجه توسط عامل‌های موجود در MARL در هر تکرار از الگوریتم، محیط پس از ارزیابی نتیجه به‌دست‌آمده به تولید پاسخ اقدام می‌کند. پاسخ محیط وابسته به مطلوب و یا نامطلوب بودن نتیجه است و در صورت مطلوب بودن آن، اقدام‌های انتخاب‌شده توسط عامل MARL طبق الگوریتم Q-یادگیری (رابطه ۲) پاداش دریافت خواهند کرد.

$$Q(S, \alpha) \leftarrow Q(S, \alpha) + lr * rd \quad (2)$$

که در این رابطه $Q(S, \alpha)$ مقدار جدید مربوط به اقدام α در موقعیت s بوده و rd مقدار پاداش دریافتی از انتخاب این است. پارامتر $0 < lr \leq 1$ با نام نرخ یادگیری، جهت تعیین سرعت یادگیری به کار می‌رود.

۴- الگوریتم تشخیص اجتماع مبتنی بر یادگیری تقویتی چندعاملی

در این بخش الگوریتم پیشنهادی با نام MARLCD برای یافتن اجتماعات در شبکه‌های پیچیده ارائه می‌شود. فرض می‌کنیم که شبکه ورودی $G = (V, E)$ یک گراف غیر جهت‌دار و بدون وزن است که در آن $V = \{v_1, v_2, \dots, v_n\}$ مجموعه رئوس و $E \subseteq V \times V$ مجموعه‌ی

یال‌ها در گراف ورودی است. $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_n\}$ به مجموعه اقدام‌های عامل در n وضعیت دلالت می‌کند و $\alpha_i = \{\alpha_i^1, \alpha_i^2, \dots, \alpha_i^{r_i}\}$ مجموعه اقدام‌های قابل انتخاب توسط عامل در موقعیت i است، و r_i برابر با تعداد رئوس مجاور با رأس v_i است. یک اقدام عامل در موقعیت i (عامل واقع بر رأس v_i) متناظر با انتخاب یک رأس مجاور با v_i است. $P_i = \{p_i^1, p_i^2, \dots, p_i^{r_i}\}$ بردار احتمال اقدام عامل در موقعیت i است و در ابتدا برای همه اقدامات i مقدار اولیه $p_i^j = 1$ در نظر گرفته شده است. در الگوریتم پیشنهادی تعدادی عامل یادگیری تقویتی (برابر با ma) به‌طور تکرارشونده اقدام به یافتن مجموعه‌ای از اجتماعات در شبکه ورودی خواهند کرد که نسبت به سایر اجتماعات با تراکم بیشتری به یکدیگر متصل هستند. تعداد تکرارهای کلی الگوریتم MARLCD برابر با MNLI بار بوده و به هر تکرار کلی یک راند گفته می‌شود. به عبارتی، ma عامل مستقل به تعداد MNLI راند به حل مسأله می‌پردازند (خطوط ۱ الی ۲۹). در هر راند از MARLCD، هر عامل به‌طور تکرارشونده اقدام به یافتن اجتماعات می‌کند (خطوط ۲ الی ۲۳) و اجتماعات یافته شده در هر راند را مورد ارزیابی قرار می‌دهد و بر اساس نتایج ارزیابی بردارهای احتمال اقدام خود را به‌روزرسانی می‌کند (خطوط ۲۴ الی ۲۷). در الگوریتم پیشنهادی، t شمارنده راند، G' مجموعه رئوس ملاقات نشده، k تعداد اجتماع یافته شده، C_k مجموعه رئوس موجود در اجتماع k ام، L^t مسیر رئوس ملاقات شده در تکرار t ام می‌باشند. در هر راند از الگوریتم پیشنهادی، k اجتماع یافته می‌شود. جزئیات یافتن k اجتماع در راند t ام به شرح زیر است (خطوط ۴ الی ۲۳):

ابتدا رأس v_i به‌صورت تصادفی از مجموعه رئوس ملاقات نشده G' انتخاب‌شده و عامل در رأس فوق قرار گرفته و این رأس در نقش موقعیت جاری عامل خواهد بود (خط ۵).

رأس v_i در مجموعه اجتماع جاری C_k و مسیر فعلی L^t درج می‌شود. سپس عامل در موقعیت متناظر با رأس v_i قرار می‌گیرد. (خطوط ۶ و ۷).

تا زمانی که تعداد کل یال‌های داخلی اجتماع جاری (C_k) کمتر از تعداد کل یال‌های خارجی C_k باشد و یا عامل فعال قادر به انتخاب اقدامی باشد (خط ۸)، فرآیند تکرار خواهد شد (خطوط ۹ الی ۲۰):

عامل یکی از اقدام‌های خود در موقعیت جاری (یکی از رئوس مجاور v_i) را مطابق با بردار احتمال اقدام

¹ state

² Multiagent Reinforcement Learning (MARL)

```

5.  $v_i \leftarrow$  a random vertex of  $G'$ 
6.  $C_k \leftarrow v_i$ 
7.  $L^t \leftarrow v_i$ 
8. While  $(d_{in}(C_k) < d_{out}(C_k)$  AND  $|\alpha_i| \neq 0$ ) Do
9. // Finding  $k^{th}$  community
10.  $\alpha_j \leftarrow$ 
an action selected by agent using  $P_i$ 
11.  $v_j \leftarrow$  vertex correspond to  $\alpha_j$ 
12. If  $(d_{in}(C_k \cup v_j) > d_{in}(C_k))$ 
13. AND  $d_{out}(C_k \cup v_j) < d_{out}(C_k)$ 
Then
14.  $C_k \leftarrow C_k \cup v_j$ 
15.  $L^t \leftarrow L^t \cup v_j$ 
16.  $v_i \leftarrow v_j$ 
17. Else
18.  $\alpha_j$  of agent is deactivated until next
round
19. End If
20. End while
21.  $G' \leftarrow G' \setminus C_k$ 
22.  $k \leftarrow k + 1$ 
23. Until  $(|G'| \neq 0)$  // making k community
24.  $NC(C^t) = \frac{1}{k} \sum_{i=1}^k \frac{cut(C_i, \bar{C}_i)}{vol(C_i)}$ 
25. If  $(NC(C^t) < NC(C^{t-1}))$ 
26. reward the selected actions along the path
 $L^t$ 
27. End If
28. Next // end of each round
29. Return  $C^t$ 

```

(شکل-۲): شبه کد الگوریتم MARLCD برای تشخیص اجتماع

در شبکه‌های پیچیده.

(Figure-2): Pseudo-code of the MARLCD algorithm for community detection in complex networks.

حال اگر مقدار برش نرمال شده در راند جاری $NC(C^t)$ کمتر یا مساوی مقدار برش نرمال شده در راند قبلی $NC(C^{t-1})$ باشد (خط ۲۵)، در این صورت اقدام‌های انتخاب‌شده در مسیر L^t ، توسط عامل مطابق با الگوریتم یادگیری توصیف‌شده در بخش قبل (رابطه ۲) پاداش دریافت خواهند کرد (خط ۲۶). پس از آنکه هر یک از ma عامل موجود، یک راند از الگوریتم را اجرا می‌کند، و نتیجه به‌دست‌آمده را مورد ارزیابی قرار می‌دهند، اگر مقدار برش نرمال یک عامل در راند جاری، کمتر از کلیه برش‌های نرمال همه عامل‌ها تا راند جاری باشد، به عامل فوق عامل موفق گفته می‌شود، و همه اقدام‌های انتخاب‌شده به‌وسیله عامل بالا در مسیر L^t ، در سایر عامل‌ها نیز طبق الگوریتم یادگیری (رابطه ۲) پاداش دریافت خواهند کرد. الگوریتم پیشنهادی به‌طور یکسان و به تعداد MNLI راند برای هر عامل اجرا خواهد شد. شکل (۲) شبه‌کد الگوریتم MARLCD را نشان می‌دهد.

خود انتخاب می‌کند، یعنی اقدام α_j (خط ۱۰). فرض می‌کنیم رأس متناظر با اقدام انتخاب‌شده به‌وسیله عامل معادل اقدام z (رأس v_j) باشد (خط ۱۱). حال اگر تعداد اتصالات داخلی بین رأس v_j و اجتماع جاری C_k بزرگ‌تر از تعداد اتصالات داخلی C_k باشد (خطوط ۱۲ و ۱۳)، آن گاه v_j را به مجموعه C_k اضافه می‌کنیم (خط ۱۴) و جایگزین رأس فعال v_i می‌شود (خط ۱۶)، همچنین رأس v_j در مسیر L^t به‌روزرسانی می‌شود (خط ۱۵). در غیر این‌صورت اقدام انتخاب‌شده (α_j) تا ابتدای راند بعدی غیر فعال خواهد شد (خط ۱۸)؛ سپس C_k از مجموعه G' حذف می‌شود (خط ۲۱) و عامل شروع به یافتن اجتماع بعدی می‌شود (خط ۲۱) و عامل شروع به یافتن اجتماع بعدی می‌شود (خط ۲۱) و عامل شروع به یافتن اجتماع بعدی می‌شود (خط ۲۱). به عبارتی، فرآیند جستجوی اجتماعات جدید مطابق با توصیف بالا و به روزرسانی مسیر رئوس ملاقات شده در تکرار جاری L^t تا زمانی که همه رئوس گراف ورودی مورد بررسی قرار بگیرد (خط ۲۳) و در یکی از اجتماعات واقع شوند (اجتماع^۱ مجموعه رئوس اجتماعات یافته‌شده برابر با شبکه ورودی G باشد)، ادامه می‌یابد (خطوط ۴ الی ۲۳)؛ سپس k اجتماع یافته‌شده در راند t ام با استفاده از تابع هدف مبتنی بر برش نرمال شده ارزیابی می‌شود (خطوط ۲۴ الی ۲۷). فرض کنیم $C^t = \{C_1, C_2, \dots, C_k\}$ مجموعه k اجتماع یافته‌شده در راند t ام باشد. کیفیت مجموعه اجتماعات یافته‌شده در این مرحله به‌وسیله تابع هدف مبتنی بر برش نرمال شده طبق معادله زیر ارزیابی می‌شود [47]:

$$NC(C^t) = \frac{1}{k} \sum_{i=1}^k \frac{cut(C_i, \bar{C}_i)}{vol(C_i)} \quad (3)$$

که در آن $cut(C_i, \bar{C}_i)$ تعداد یال‌های بین C_i و سایر اجتماعات یافته‌شده (\bar{C}_i) و $vol(C_i)$ درجه کل رئوس عضو اجتماع C_i و همچنین k تعداد اجتماعات هستند. برش نرمال شده با پیچیدگی پایین، به‌جای ارزیابی ویژگی‌های محلی، مانند شباهت‌های بین اعضای یک اجتماع و تفاوت‌های بین اجتماعات مختلف، استخراج تأثیر سراسری شبکه را در نظر می‌گیرد و در طی اجرای الگوریتم، برش نرمال شده به‌تدریج کاهش می‌یابد. یعنی الگوریتم به‌تدریج به برش نرمال شده کمینه هم‌گرا و به مجموعه اجتماعات مناسب هم‌گرا می‌شود [48].

1. For $t = 1$ to MNLI
2. $G' \leftarrow G$
3. $k \leftarrow 1$
4. Repeat // making k community

¹ union



۵- نتایج تجربی

در این بخش، برای ارزیابی کارایی راه کار پیشنهادی MALRCD از چهار شبکه واقعی مشهور و شبکه‌های مصنوعی مقیاس بزرگ از مجموعه محک (benchmark) LFR استفاده شده است. جدول (۱) شبکه‌های مورد استفاده در آزمایش‌ها را نشان می‌دهد. همچنین راه کار پیشنهادی را با چندین الگوریتم مطرح در این زمینه به طور نظام مند مورد مقایسه قرار می‌دهیم. راه کار پیشنهادی تحت میکروسافت ویژوال استودیو دات نت ۲۰۱۳ با سیستم عامل ۶۴ بیتی و ویندوز ۸ پیاده سازی می‌شود و اجرای همه آزمایش‌ها بر روی رایانه با پردازنده Intel Core-i5-4200U، 1.6 GHz و حافظه اصلی 4 GB انجام شده است. نظر به اینکه راه کار پیشنهادی و الگوریتم‌های مورد مقایسه دارای اجزا تصادفی هستند و امکان تولید نتایج متفاوت در اجراهای مختلف وجود دارد؛ بنابراین هر آزمایش به تعداد بیست بار به طور مستقل اجرا و میانگین نتایج به دست آمده از آن‌ها ثبت شده است.

(جدول-۱): اطلاعات شبکه‌های به کار رفته

در آزمایش‌های تجربی.

(Table-1): Networks' information used in experiments.

توصیف	تعداد یال‌ها	تعداد رئوس (n)	شبکه
شبکه کلومپ کاراته زچاری [49]	78	34	Karate
شبکه دلفین‌ها [50]	159	62	Dolphins
شبکه کتب سیاسی آمریکایی [51]	441	105	Books
شبکه تیم‌های فوتبال کالج آمریکایی [17]	615	115	Football
شبکه مصنوعی از مجموعه LFR [52]	38160	1000	LFR1
شبکه مصنوعی از مجموعه LFR	250000	5000	LFR2

برای ارزیابی عملکرد MALRCD و سایر الگوریتم‌های تشخیص اجتماع مورد مقایسه، از دو معیار ارزیابی استاندارد رایج شامل Q-ماجولاریتی و NMI استفاده کرده‌ایم. معیار Q-ماجولاریتی، یکی از معیارهای رایج ارزیابی مجموعه اجتماعات یافته شده در شبکه‌ها به وسیله الگوریتم‌ها است که به صورت زیر تعریف می‌شود: [21]:

$$Q = \frac{1}{2m} \sum_{C \in P} \sum_{v_i, v_j \in C} \left[A_{i,j} - \frac{k_i k_j}{2m} \right] \quad (4)$$

که در آن A ماتریس همسایگی است و اگر یالی بین رئوس v_i و v_j وجود داشته باشد، $A_{i,j}$ برابر با ۱ خواهد بود و در غیر این صورت برابر صفر است. $k_i = \sum_j A_{i,j}$ به درجه راس v_i دلالت دارد و m تعداد کل یال‌ها در شبکه است. جمع بندی بر روی همه جفت رئوس عضو اجتماع C از پارتیشن P انجام می‌گیرد.

معیار اطلاعات متقابل نرمال شده^۱ (NMI)، نیز یکی از معیارهای مهم ارزیابی نتایج الگوریتم‌های تشخیص اجتماع است که برای تخمین شباهت بین اجتماعات تشخیص داده شده توسط الگوریتم و اجتماعات واقعی بکار می‌رود. فرض کنید A و B دو پارتیشن از یک شبکه هستند و C_A بیانگر تعداد اجتماعات در A و C_B بیانگر تعداد اجتماعات در B است. D ماتریس آشفتگی و $D_{i,j}$ به تعداد گره‌ها در اجتماع i از A که در اجتماع j از B نیز ظاهر می‌شوند دلالت دارند. n تعداد گره‌ها است. D_i جمع بر روی سطر i از D و D_j جمع بر روی ستون j است. تعریف $NMI(A, B)$ به صورت زیر است:

$$MI(A, B) = \frac{-2 \sum_{i=1}^{C_A} \sum_{j=1}^{C_B} D_{i,j} \log \left(\frac{D_{i,j} n}{D_i D_j} \right)}{\sum_{i=1}^{C_A} D_i \log \left(\frac{D_i}{n} \right) + \sum_{j=1}^{C_B} D_j \log \left(\frac{D_j}{n} \right)}$$

NMI مقداری بین [0,1] داشته و مقادیر بالاتر نشان می‌دهد که اجتماعات A و B کاملاً مستقل هستند [53]. این معیار به طور معمول برای شبکه‌هایی به کار می‌رود که در مورد اجتماعات واقعی آن‌ها دانش قبلی داشته باشیم.

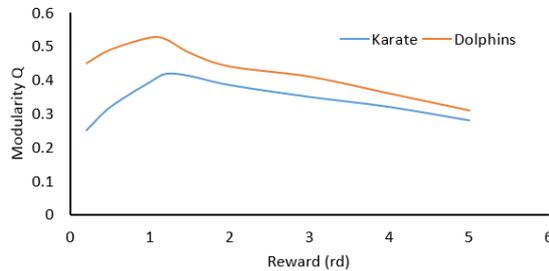
۵-۱- تنظیمات پارامتری راه کار MARLCD

مقادیر تعیین شده برای پارامترهای MARLCD، بر اساس تعدادی از آزمایش‌ها بوده و مقدار در نظر گرفته شده برای آن‌ها طوری است که بهترین نتیجه با توجه به کیفیت جواب و زمان محاسباتی مورد نیاز به دست می‌آید. جدول (۲) تنظیمات پارامتری راه کار پیشنهادی را نشان می‌دهد. باین وجود در ادامه دلایل تنظیم مقادیر برخی از پارامترهای مهم به کار رفته را بر اساس نتایج برخی از آزمایش‌ها مورد بررسی قرار می‌دهیم.

هنگام توسعه الگوریتم‌های مبتنی بر عامل‌های هوشمند، انتخاب پارامترهای یادگیری مناسب تأثیر به سزایی در کارایی الگوریتم دارد. برای مثال پارامتر نرخ یادگیری از آن جمله است [54]. به عبارتی یادگیری دقیق در الگوریتم‌های یادگیری تقویتی به شدت به تنظیم دقیق

¹ Normalized Mutual Information

به زیر یک و میل به سمت صفر، کارایی الگوریتم به طور زیادی کاهش می‌یابد. هم‌چنین با افزایش آن به مقادیر بیش از یک، تأثیر نامطلوبی در کارایی الگوریتم مشاهده می‌شود؛ بنابراین پارامتر پاداش rd تعیین شده برای عامل‌های موجود در MARLCD، در بازه $[0.8, 1.3]$ قرار می‌گیرد و هر یک از عامل‌ها به‌طور مستقل، مقداری را در این بازه اختیار خواهد کرد.



(شکل-۴): نتایج اجرای MARLCD بر روی شبکه‌های Karate و Dolphins با پارامتر پاداش متفاوت بر اساس مقدار Q -ماجولاریتی

(Figure-4): Results of MARLCD on Karate and Dolphins networks with different values of the reward based on Q -modularity.

۲-۵- آزمایش‌ها بر روی شبکه‌های واقعی

در شکل (۵)، بهترین نتیجه به‌دست‌آمده به‌وسیله MARLCD بر روی شبکه Dolphin نشان داده شده است. طبق شکل (۵)، تعداد خوشه‌های یافته شده توسط الگوریتم برابر ۲ است که منطبق بر نتیجه واقعی این شبکه است. در این بخش نتایج اجرای الگوریتم پیشنهادی و تعدادی از متدهای مطرح در زمینه تشخیص اجتماع از جمله GA-Net توسط پیژوتی [30]، Meme-Net توسط گونگ و همکاران [32]، LPA توسط لیو و موراتا [34] و MAGA-Net توسط لی و لیو [38] برحسب معیارهای Q -ماجولاریتی و NMI بر روی شبکه‌های دنیای واقعی گزارش شده است و مقایسه می‌شود. نتایج به‌دست‌آمده به وسیله روش‌های مختلف برحسب معیار Q -ماجولاریتی در جدول (۳) ارائه شده است.

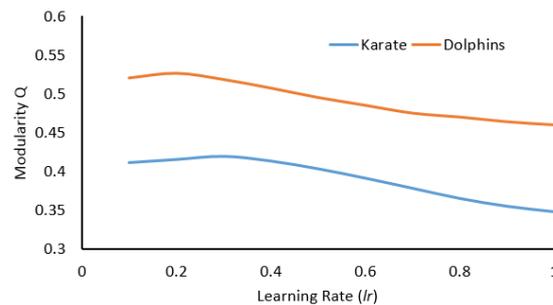
با توجه به نتایج جدول (۳)، برای شبکه‌های Karate، Books و Football، الگوریتم پیشنهادی بر اساس معیار Q -ماجولاریتی میانگین (Q_{avg}) از سایر متدها عملکرد بهتری و یا لافل برابری را نشان می‌دهد. همچنین برای شبکه Dolphins، نتایج حاصل از الگوریتم پیشنهادی از متدهای GA-Net، Meme-Net و LPA بهتر و در مقایسه با متد MAGA-Net، اندکی ضعیف‌تر و می‌توان گفت که در محدوده مشابهی تقریباً قرار دارد و میانگین Q_{avg} به‌دست‌آمده توسط MARLCD، تقریباً $12/33\%$

پارامترهای یادگیری وابسته بوده و تحصیل نتایج باکیفیت و رسیدن به کارایی خوب به‌طور حیاتی با تنظیم پارامترهای یادگیری مرتبط است [55]. شکل (۳) نتایج اجرای الگوریتم MARLCD با مقادیر مختلف نرخ یادگیری را نشان می‌دهد. در این شکل مقادیر Q -ماجولاریتی برای شبکه‌های Karate و Dolphins با نرخ یادگیری متغیر از ۰.۱ تا ۱ به تصویر کشیده شده است. از نمودار این شکل می‌توان نتیجه گرفت که عملکرد الگوریتم MARLCD به انتخاب نرخ یادگیری وابستگی کاملی داشته و معمولاً مقادیر کم نرخ یادگیری منجر به عملکرد بهتر الگوریتم در شبکه‌های موردبررسی می‌شود، درحالی‌که مقادیر بزرگ منجر به عملکرد بدتر می‌شود. طبق نتایج به‌دست‌آمده، در بازه معینی از مقدار lr ($[0.15, 0.35]$)، الگوریتم عملکرد بهتری را نشان می‌دهد، در نتیجه نرخ یادگیری lr تعیین شده برای عامل‌های موجود در الگوریتم MARLCD، در بازه $[0.15, 0.35]$ خواهد بود و هر یک از عامل‌ها به‌طور مستقل، مقداری را در این بازه اختیار خواهد کرد.

(جدول-۲): تنظیمات پارامتری برای راهکار MARLCD.

(Table-2): Parameter settings for MARLCD approach.

پارامتر	مقدار	مفهوم
rd	$[0.8, 1.3]$	پاداش
lr	$[0.15, 0.35]$	نرخ یادگیری
ma	5	تعداد عامل‌ها
$MNLI$	$2000 * n$	حداکثر تعداد تکرارهای یادگیری

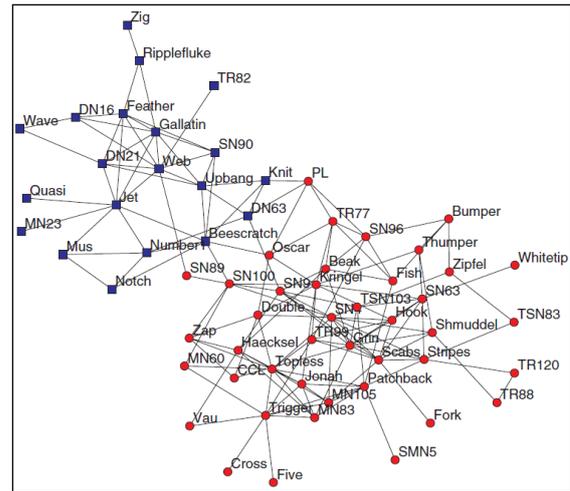


(شکل-۳): نتایج اجرای MARLCD بر روی شبکه‌های Karate و Dolphins با نرخ‌های یادگیری متفاوت بر اساس مقدار Q -ماجولاریتی.

(Figure-3): Results of MARLCD on Karate and Dolphins networks with different learning rates based on Q -modularity.

در شکل (۴) وقتی مقدار پارامتر پاداش rd حوالی عدد ۱ است، نتایج بهتری دیده می‌شود، اما با کاهش آن

بیشتر از میانگین Q_{avg} به دست آمده توسط سه الگوریتم دیگر است. از دیدگاه بیشترین Q-ماجولاریتی به دست آمده (Q_{max})، روش پیشنهادی در هر چهار شبکه مورد بررسی، از همه روش‌های مقایسه شده، از کیفیت بالاتری برخوردار است و بهترین نتایج را تولید می‌کند، که بدین معنی است که الگوریتم پیشنهادی قادر به یافتن اجتماعات مناسب است. همچنین زمان محاسباتی متد پیشنهادی نیز در هر چهار شبکه Karate, Dolphins, Books, و Football کمتر از دو الگوریتم LPA و MAGA-Net است (برای دو الگوریتم Meme-Net و GA-Net زمان محاسباتی گزارش نشده است).



(شکل-۵): دو خوشه یافته شده توسط MARLCD

برای شبکه Dolphin.

(Figure-5): Two communities found by MARLCD for Dolphin Network.

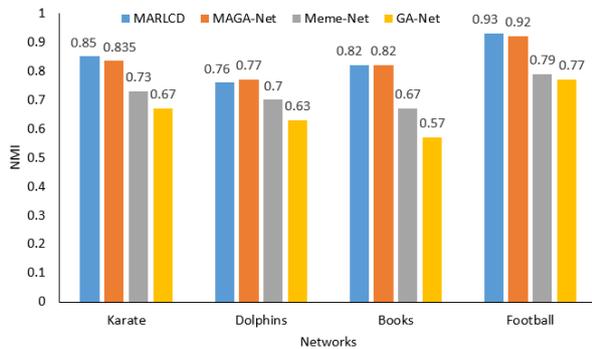
(جدول-۳): مقایسه MARLCD و الگوریتم‌های GA-Net.

MAGA-Net و LPA، Meme-Net بر حسب معیار Q-ماجولاریتی.

(Table-3): Comparison of MARLCD and GA-Net, Meme-Net, LPA and MAGA-Net methods according to Q-modularity.

روش شبکه		Karate	Dolphins	Books	Football	Avg.
GA-Net	Q_{avg}	0.374	0.492	0.487	0.502	0.464
	Q_{max}	0.419	0.522	0.521	0.556	0.505
	Q_{std}	0.076	0.011	0.036	0.023	0.037
	Time(s)					
Meme-Net	Q_{avg}	0.408	0.427	0.443	0.490	0.442
	Q_{max}	0.419	0.502	0.513	0.549	0.496
	Q_{std}	0.013	0.305	0.021	0.023	0.091
	Time(s)					
LPA	Q_{avg}	0.352	0.495	0.493	0.579	0.48
	Q_{max}	0.399	0.516	0.522	0.604	0.51
	Q_{std}	0.028	0.008	0.020	0.018	0.019
	Time(s)	0.009	0.019	0.048	0.049	0.031
MAGA-Net	Q_{avg}	0.419	0.527	0.527	0.602	0.519
	Q_{max}	0.419	0.528	0.527	0.604	0.52
	Q_{std}	0.002	0.001	0.001	0.003	0.002
	Time(s)	0.021	0.073	0.268	0.378	0.185
MARLCD	Q_{avg}	0.419	0.526	0.527	0.603	0.519
	Q_{max}	0.420	0.528	0.527	0.607	0.521
	Q_{std}	0.001	0.001	0.001	0.002	0.001
	Time(s)	0.016	0.052	0.143	0.309	0.13

نتایج به دست آمده از اجرای الگوریتم MARLCD و الگوریتم‌های GA-Net، Meme-Net و MAGA-Net بر روی شبکه‌های واقعی، بر حسب معیار NMI در شکل (۶) گزارش شده است. از این معیار به طور برای اندازه‌گیری شباهت بین اجتماعات تشخیص داده شده به وسیله الگوریتم‌ها و نتایج واقعی استفاده می‌شود. همان‌گونه که از شکل (۶) مشاهده می‌شود، اجتماع به دست آمده توسط MARLCD در مقایسه با سه الگوریتم دیگر، به جز نتیجه به دست آمده به وسیله الگوریتم MAGA-Net برای شبکه Dolphins، در سایر شبکه‌ها، از شباهت بیشتری به نتایج واقعی برخوردار بوده و میانگین NMI به دست آمده به وسیله MARLCD، تقریباً ۹۱/۸۵٪ بیشتر از میانگین NMI به دست آمده به وسیله سه الگوریتم دیگر است، یعنی اجتماعات تشخیص داده شده به وسیله الگوریتم پیشنهادی در مقایسه با الگوریتم‌های GA-Net، Meme-Net و MAGA-Net، به طور متوسط ۹۱/۸۵٪ از شباهت بیشتری به نتایج واقعی برخوردار است.



(شکل-۶): مقایسه مقادیر میانگین NMI به دست آمده توسط

MARLCD و متدهای GA-Net، Meme-Net و MAGA-Net در

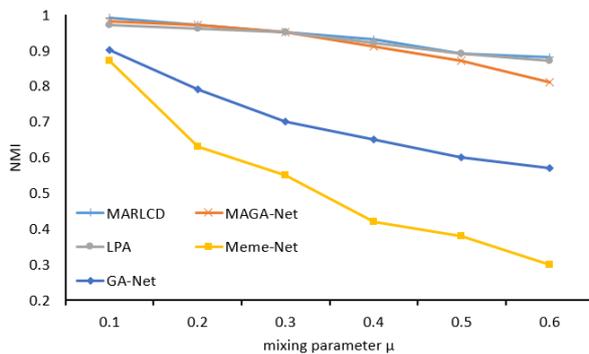
چهار شبکه Karate، Dolphins، Books و Football.

(Figure-6): Comparison of the mean NMI values obtained by MARLCD and GA-Net, Meme-Net and MAGA-Net methods in four Karate, Dolphins, Books and Football networks.

۳-۵- آزمایش‌ها بر روی شبکه‌های مصنوعی

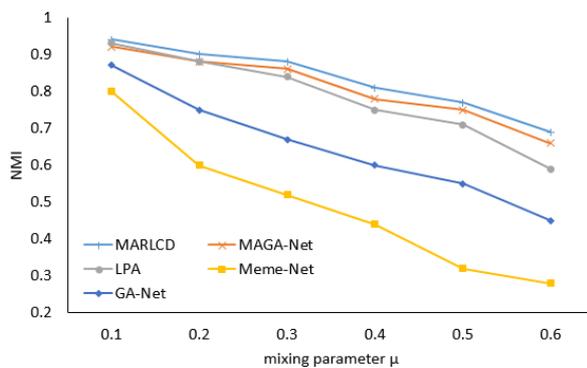
در ادامه به منظور بررسی کارایی الگوریتم MARLCD، از شبکه‌های مصنوعی متعلق به مجموعه محک LFR استفاده می‌شود، و تعدادی شبکه با مقیاس‌های ۱۰۰۰ و ۵۰۰۰ گره‌ای ایجاد کرده‌ایم. شبکه‌های مصنوعی LFR، توسط لانسچینتی و همکاران [52] ارائه شده است و برای سنجش نظام‌مند کیفیت الگوریتم‌های تشخیص اجتماع، مناسب هستند. در آزمایش‌های انجام شده، شش شبکه مختلف با اندازه هزار گره‌ای (LFR1) و با مقادیر پارامتر ترکیبی μ برابر با ۰/۱، ۰/۲، ۰/۳، ۰/۴، ۰/۵ و ۰/۶ و همچنین ۶ شبکه دیگر با

قابل قبولی را تولید کند. همان گونه که در قبل نیز بیان شد، تغییر مقدار μ از $0/1$ به $0/6$ باعث پیچیده تر شدن تشخیص اجتماع می شود، با این وجود MARLCD در مقادیر بالای پارامتر ترکیبی نیز عملکرد خوبی از خود نشان می دهد که کیفیت بالای راه کار پیشنهادی را به طور جامع مورد تأیید قرار می دهد. همچنین میانگین NMI به دست آمده به وسیله MARLCD، به طور تقریبی $21/89\%$ بیشتر از میانگین NMI به دست آمده به وسیله چهار الگوریتم دیگر است.



(شکل ۷): مقایسه مقادیر میانگین NMI حاصل از اجرای MARLCD و الگوریتم های GA-Net، Meme-Net، LPA و MAGA-Net بر روی شبکه های مصنوعی LFR با ۱۰۰۰ گره (LFR1) با مقدار پارامتر ترکیبی μ از $0/1$ تا $0/6$.

(Figure-7): Comparison of the mean NMI values obtained by MARLCD and GA-Net, Meme-Net and MAGA-Net methods on 1000 nodes LFR synthetic networks (LFR1) with μ parameter values from 0.1 to 0.6.



(شکل ۸): مقایسه مقادیر میانگین NMI حاصل از اجرای MARLCD و الگوریتم های GA-Net، Meme-Net، LPA و MAGA-Net بر روی شبکه های مصنوعی LFR با ۵۰۰۰ گره (LFR2) و مقدار پارامتر ترکیبی μ از $0/1$ تا $0/6$.

(Figure-8): Comparison of the mean NMI values obtained by MARLCD and GA-Net, Meme-Net and MAGA-Net methods on 5000 nodes LFR synthetic networks (LFR2) with μ parameter values from 0.1 to 0.6.

بر اساس ارزیابی های انجام گرفته و نتایج گزارش شده در این بخش، MARLCD در مقایسه با سایر

اندازه ۵۰۰۰ گره ای (LFR2) و با مقادیر پارامتر ترکیبی μ مشابه با شبکه های قبلی ایجاد کرده ایم. پارامتر ترکیبی μ به نسبت یال ها در میان اجتماعات دلالت دارد و هر رأس کسری از $1 - \mu$ یال خود را با رئوس موجود در اجتماع خود و کسری از μ یال خود را با دیگر رئوس شبکه به اشتراک می گذارد.

گفتنی است که با افزایش مقدار پارامتر ترکیبی، شناسایی اجتماعات سخت تر می شود. سایر پارامترهای شبکه های LFR ایجاد شده به صورت زیر هستند: پارامتر درجه متوسط گره ها معادل $K = 15$ ، بیشینه درجه گره ها برابر با $max_k = 50$ ، کمینه اندازه اجتماعات برابر با $min_c = 10$ و بیشینه اندازه اجتماعات به صورت $max_c = 50$ تنظیم شده اند. در شکل های (۷ و ۸) مقادیر میانگین NMI حاصل از اجرای MARLCD و الگوریتم های GA-Net، Meme-Net، LPA و MAGA-Net نشان داده شده است.

همان طور که از شکل (۷) مشاهده می شود، برای اندازه های کوچک پارامتر ترکیبی μ ، همه الگوریتم تقریباً نتایج یکسان و با مقادیر NMI بالا را به دست آورده اند که نشانگر کیفیت قابل قبول آن ها در این دسته از شبکه هاست. اما با افزایش مقدار پارامتر ترکیبی که منجر به افزایش پیچیدگی شبکه می شود، کیفیت نتایج الگوریتم های مختلف بر اساس مقدار NMI کاهش می یابد. همچنین این شکل نشان می دهد که الگوریتم های MARLCD، LPA و MAGA-Net در شبکه های LFR با ۱۰۰۰ گره از کارایی خوبی بوده و مقدار NMI آن ها برای مقادیر پارامتر ترکیبی μ از $0/1$ تا $0/6$ از مقدار 1 تا $0/85$ متغیر است، که بر شباهت بالای اجتماعات تشخیص داده شده توسط این الگوریتم ها با نتایج واقعی دلالت دارد. همچنین محدودیت های الگوریتم های GA-Net و Meme-Net و ضعف نتایج به دست آمده توسط آن ها با افزایش مقدار μ قابل مشاهده است. علاوه بر این میانگین NMI به دست آمده توسط MARLCD، تقریباً $21/71\%$ بیشتر از میانگین NMI به دست آمده توسط چهار الگوریتم دیگر است.

نتایج نشان داده شده در شکل (۸) بیانگر ضعف بالای راه کارهای GA-Net و Meme-Net در شبکه های با مقیاس بالا، بخصوص در مقادیر بالای پارامتر ترکیبی است، در حالی که روش های LPA، MARLCD و MAGA-Net قادرند برای شبکه های با اندازه بسیار بزرگ نیز نتایج

- [8] J. Liu, W. Zhong, and L. Jiao, "A multiagent evolutionary algorithm for constraint satisfaction problems," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 36, no. 1, pp. 54-73, 2006.
- [9] M. M. Alipour and S. N. Razavi, "A new multiagent reinforcement learning algorithm to solve the symmetric traveling salesman problem," *Multiagent and Grid Systems*, vol. 11, no. 2, pp. 107-119, 2015.
- [10] M. M. Alipour, S. N. Razavi, M. R. F. Derakhshi, and M. A. Balafar, "A hybrid algorithm using a genetic algorithm and multiagent reinforcement learning heuristic to solve the traveling salesman problem," *Neural Computing and Applications*, pp. 1-17, 2017.
- [11] M. M. Alipour and M. Abdolhosseinzadeh, "A multiagent reinforcement learning algorithm to solve the maximum independent set problem," *Multiagent and Grid Systems*, vol. 16, no. 1, pp. 101-115, 2020.
- [12] M. E. Newman, "Modularity and community structure in networks," *Proceedings of the national academy of sciences*, vol. 103, no. 23, pp. 8577-8582, 2006.
- [13] A. Clauset, M. E. Newman, and C. Moore, "Finding community structure in very large networks," *Physical review E*, vol. 70, no. 6, p. 066111, 2004.
- [14] J. M. Kumpula, J. Saramäki, K. Kaski, and J. Kertész, "Limited resolution and multiresolution methods in complex network community detection," *Fluctuation and Noise Letters*, vol. 7, no. 03, pp. L209-L214, 2007.
- [15] S. Fortunato, "Community detection in graphs," *Physics reports*, vol. 486, no. 3-5, pp. 75-174, 2010.
- [16] L. Donetti and M. A. Munoz, "Detecting network communities: a new systematic and efficient algorithm," *Journal of Statistical Mechanics: Theory and Experiment*, vol. 2004, no. 10, pp. P10012, 2004.
- [17] 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.
- [18] M. E. Newman and M. Girvan, "Finding and evaluating community structure in networks," *Physical review E*, vol. 69, no. 2, pp. 026113, 2004.
- [19] F. Radicchi, C. Castellano, F. Cecconi, V. Loreto, and D. Parisi, "Defining and identifying communities in networks," *Proceedings of the national academy of sciences*, vol. 101, no. 9, pp. 2658-2663, 2004.
- [20] L. Hagen and A. B. Kahng, "A new approach to effective circuit clustering," in *ICCAD*, 1992, vol. 92, pp. 422-427.
- [21] P. De Meo, E. Ferrara, G. Fiumara, and A. Provetti, "Mixing local and global information

الگوریتم‌های مطرح در زمینه تشخیص اجتماع، عملکرد بهتر و باثبات‌تری دارد، و از سرعت هم‌گرایی بالایی برخوردار است، و نتایج تولیدشده توسط آن در شبکه‌های با مقیاس کوچک و بزرگ از پایداری خوبی برخوردار بوده و قابلیت مدیریت شبکه‌های با مقیاس بزرگ تا پنج‌هزار گره را نیز دارد.

۶- نتیجه‌گیری

در این مقاله الگوریتمی جدید مبتنی بر یادگیری تقویتی چندعاملی جهت تشخیص اجتماع در شبکه‌های پیچیده ارائه کرده‌ایم که در سامانه چندعاملی پیشنهادی، هر عامل یک موجودیت مستقل با پارامترهای یادگیری مختلف بوده و عامل‌های موجود در این شبکه با همکاری و تعامل، سعی در شناسایی اجتماعات محلی با تراکم بالا دارند. عملکرد الگوریتم پیشنهادی به‌طور تجربی بر روی چهار شبکه واقعی مشهور و تعدادی شبکه مصنوعی LFR، ارزیابی شد و با تعدادی از الگوریتم‌های مشهور تشخیص اجتماع مورد مقایسه قرار گرفت. با توجه به نتایج به‌دست‌آمده، الگوریتم پیشنهادی بر اساس معیار $-Q$ ماجولاریتی و NMI، قابلیت رقابت و غلبه بر الگوریتم‌های مورد مقایسه را داشته و می‌تواند بهترین پارتیشن‌ها را با سرعت بالا، دقت و پایداری مناسب پیدا کند.

7- References

۷- مراجع

- [1] D. J. Watts and S. H. Strogatz, "Collective dynamics of 'small-world' networks," *nature*, vol. 393, no. 6684, pp. 440, 1998.
- [2] S. Boccaletti, V. Latora, Y. Moreno, M. Chavez, and D.-U. Hwang, "Complex networks: Structure and dynamics," *Physics reports*, vol. 424, no. 4-5, pp. 175-308, 2006.
- [3] M. E. Newman, "The structure and function of complex networks," *SIAM review*, vol. 45, no. 2, pp. 167-256, 2003.
- [4] S. Wasserman and K. Faust, *Social network analysis: Methods and applications*. Cambridge university press, 1994.
- [5] R. Milo, S. Shen-Orr, S. Itzkovitz, N. Kashtan, D. Chklovskii, and U. Alon, "Network motifs: simple building blocks of complex networks," *Science*, vol. 298, no. 5594, pp. 824-827, 2002.
- [6] U. Brandes et al., "On modularity clustering," *IEEE transactions on knowledge and data engineering*, vol. 20, no. 2, pp. 172-188, 2007.
- [7] J. Liu, W. Zhong, and L. Jiao, "A multiagent evolutionary algorithm for combinatorial optimization problems," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 40, no. 1, pp. 229-240, 2009.

- community detection in complex networks using multiobjective evolutionary algorithms," in IEEE Congress on Evolutionary Computation, 2010: IEEE, pp. 1-7.
- [34] X. Liu and T. Murata, "Advanced modularity-specialized label propagation algorithm for detecting communities in networks," *Physica A: Statistical Mechanics and its Applications*, vol. 389, no. 7, pp. 1493-1500, 2010.
- [35] J. Duch and A. Arenas, "Community detection in complex networks using extremal optimization," *Physical review E*, vol. 72, no. 2, p. 027104, 2005.
- [36] B. Yang and D.-Y. Liu, "Force-based incremental algorithm for mining community structure in dynamic network," *Journal of Computer Science and Technology*, vol. 21, no. 3, pp. 393-400, 2006.
- [37] I. Gunes and H. Bingol, "Community detection in complex networks using agents," arXiv preprint cs/0610129, 2006.
- [38] Z. Li and J. Liu, "A multi-agent genetic algorithm for community detection in complex networks," *Physica A: Statistical Mechanics and its Applications*, vol. 449, pp. 336-347, 2016.
- [39] J. Huang, B. Yang, D. Jin, and Y. Yang, "Decentralized mining social network communities with agents," *Mathematical and Computer Modelling*, vol. 57, no. 11-12, pp. 2998-3008, 2013.
- [40] G. Palla, I. Derényi, I. Farkas, and T. Vicsek, "Uncovering the overlapping community structure of complex networks in nature and society," *nature*, vol. 435, no. 7043, p. 814, 2005.
- [41] S. J. Russell and P. Norvig, *Artificial intelligence: a modern approach*. Malaysia: Pearson Education Limited, 2016.
- [42] R. S. Sutton and A. G. Barto, *Reinforcement learning: An introduction*. Cambridge: MIT press, 1998.
- [43] L. P. Kaelbling, M. L. Littman, and A. W. Moore, "Reinforcement learning: A survey," *Journal of Artificial Intelligence Research*, vol. 4, pp. 237-285, 1996.
- [44] P. Stone and M. Veloso, "Multiagent systems: A survey from the machine learning perspective," *Autonomous Robots*, vol. 8, no. 3, pp. 345-383, 2000.
- [45] S. Sen and G. Weiss, "Learning in multiagent systems," in *Multiagent Systems: A Modern Approach to Distributed Artificial Intelligence*, G. Weiss Ed.: MIT Press, 1999, ch. 6, pp. 259-298.
- [46] R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*. MIT Press, 1998.
- [47] I. S. Dhillon, Y. Guan, and B. Kulis, "Kernel k-means: spectral clustering and normalized for community detection in large networks," *Journal of Computer and System Sciences*, vol. 80, no. 1, pp. 72-87, 2014.
- [22] J. Cao, Z. Bu, Y. Wang, H. Yang, J. Jiang, and H.-J. Li, "Detecting prosumer-community groups in smart grids from the multiagent perspective," *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 49, no. 8, pp. 1652-1664, 2019.
- [23] C.-K. Han, S.-F. Cheng, and P. Varakantham, "A Homophily-Free Community Detection Framework for Trajectories with Delayed Responses," in *Proceedings of the 18th International Conference on Autonomous Agents and MultiAgent Systems, 2019: International Foundation for Autonomous Agents and Multiagent Systems*, pp. 2003-2005.
- [24] X. Feng and X. Yang, "Fast convergent average consensus of multiagent systems based on community detection algorithm," *Advances in Difference Equations*, vol. 2018, no. 1, pp. 1-13, 2018.
- [25] P. Pons and M. Latapy, "Computing communities in large networks using random walks," *J. Graph Algorithms Appl.*, vol. 10, no. 2, pp. 191-218, 2006.
- [26] P. Ronhovde and Z. Nussinov, "Multiresolution community detection for megascale networks by information-based replica correlations," *Physical Review E*, vol. 80, no. 1, p. 016109, 2009.
- [27] M. Zhou and J. Liu, "A memetic algorithm for enhancing the robustness of scale-free networks against malicious attacks," *Physica A: Statistical Mechanics and its Applications*, vol. 410, pp. 131-143, 2014.
- [28] T. N. Bui and B. R. Moon, "Genetic algorithm and graph partitioning," *IEEE Transactions on computers*, vol. 45, no. 7, pp. 841-855, 1996.
- [29] M. Tasgin, A. Herdagdelen, and H. Bingol, "Community detection in complex networks using genetic algorithms," arXiv preprint arXiv:0711.0491, 2007.
- [30] C. Pizzuti, "Ga-net: A genetic algorithm for community detection in social networks," in *International conference on parallel problem solving from nature, 2008: Springer*, pp. 1081-1090.
- [31] A. Gog, D. Dumitrescu, and B. Hirsbrunner, "Community detection in complex networks using collaborative evolutionary algorithms," in *European Conference on Artificial Life, 2007: Springer*, pp. 886-894.
- [32] M. Gong, B. Fu, L. Jiao, and H. Du, "Memetic algorithm for community detection in networks," *Physical Review E*, vol. 84, no. 5, p. 056101, 2011.
- [33] J. Liu, W. Zhong, H. A. Abbass, and D. G. Green, "Separated and overlapping





محسن عبدالحسین زاده فارغ
التحصیل رشته ریاضی کاربردی
گرایش پژوهش در عملیات است. وی
در زمینه تخصصی بهینه‌سازی شبکه
به پژوهش می‌پردازد. از جمله

حوزه‌های پژوهشی مورد علاقه ایشان می‌توان بهینه‌سازی
ترکیبیاتی، الگوریتم‌های ابتکاری و فراابتکاری و مدل‌های
تصادفی و غیرقطعی را نام برد. نام‌برده هم‌اکنون به‌عنوان
عضو هیأت علمی گروه ریاضی و علوم کامپیوتر دانشگاه
بناب مشغول به کار بوده، و همچنین عضو پیوسته انجمن
ایرانی پژوهش در عملیات است.
نشانی رایانامه ایشان عبارت است از:

mohsen.ab@ubonab.ac.ir

cuts," in Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining, 2004: ACM, pp. 551-556.

- [48] J. Shi and J. Malik, "Normalized cuts and image segmentation," Departmental Papers (CIS), pp. 107, 2000.
- [49] 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.
- [50] 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.
- [51] V. Krebs, "Books about us politics," unpublished, <http://www.orgnet.com>, 2004.
- [52] A. Lancichinetti, S. Fortunato, and F. Radicchi, "Benchmark graphs for testing community detection algorithms," *Physical review E*, vol. 78, no. 4, p. 046110, 2008.
- [53] L. Danon, A. Diaz-Guilera, J. Duch, and A. Arenas, "Comparing community structure identification," *Journal of Statistical Mechanics: Theory and Experiment*, vol. 2005, no. 09, pp. P09008, 2005.
- [54] M. Tokic, F. Schwenker, and G. Palm, "Meta-learning of exploration and exploitation parameters with replacing eligibility traces," presented at the In IAPR International Workshop on Partially Supervised Learning (pp. 68-79). Springer Berlin Heidelberg, 2013, May.
- [55] K. Kobayashi, H. Mizoue, T. Kuremoto, and M. Obayashi, "A meta-learning method based on temporal difference error," presented at the In International Conference on Neural Information Processing (pp. 530-537). Springer Berlin Heidelberg, 2009, December.



میر محمد علیپور در رشته مهندسی
کامپیوتر گرایش هوش مصنوعی فارغ
التحصیل شده است. زمینه‌های پژوهشی
وی شامل یادگیری ماشین، الگوریتم‌های
اکتشافی و فرااکتشافی، هوش جمعی،

بهینه‌سازی ترکیبی و به‌ویژه یادگیری چندعاملی و
کاربردهای آن است. وی هم‌اکنون به‌عنوان استادیار گروه
مهندسی کامپیوتر دانشگاه بناب مشغول به کار است.
نشانی رایانامه ایشان عبارت است از:

alipour@ubonab.ac.ir