

Community Detection in Social Networks Using Deep Learning Approach

Monireh Hosseini *

Associate Professor, Information Technology Engineering Dept., Faculty of Industrial Engineering, K.N.Toosi University of Technology, Tehran, Iran.

Elnaz Galavi 

M. Sc. Student in, Information Technology Engineering, K.N.Toosi University of Technology, Tehran, Iran.

1. Introduction

Today, due to the increasing use of the Internet, social networks have found an important role in the real life of people. In social networks, some nodes are more connected than the entire network nodes, which are called communities (Sperli, 2019). Community Detection is an important topic for social network analysis and is also essential to understanding complex network structure. In community detection, the goal is to determine the groups in which the group nodes are densely connected.

There are many methods for community detection, but deep learning has shown excellent performance in a wide range of research fields, such as social networks, graph embedding, etc.

In this research, deep learning techniques have been used to control graph data with high dimensions, while presenting a comprehensive and integrated architecture of community detection methods with deep learning.

Research Questions

Is it possible to create a new similarity matrix from the graph of complex networks that fully reveals the similarity relationships between network nodes?

* Corresponding Author: hosseini@kntu.ac.ir

How to Cite: Hosseini, M., Galavi, E. (2023). Community Detection in Social Networks Using Deep Learning Approach, *Journal of Business Intelligence Management Studies*, 11(44), 83-112.

What is the appropriate method of deep learning to represent the features of complex networks in low dimensions?

Is it possible to provide a suitable framework with model flexibility for networks of different sizes for community detection using the deep learning method?

Can more accurate clustering results be achieved for community detection?

2. Literature Review

2.1. Community detection classic approaches are suitable for networks with low dimensions. Therefore, the reduction of complex network dimensions is counted as a significant topic in community detection. The disadvantage of the high-dimensional network is the huge computational costs incurred by community detection methods. Therefore, a method is needed to transform high-dimensional graphs into a lower-dimensional space, where important information about network structure and node properties is still preserved. According to past research, autoencoders are the dominant method for mapping data points in lower-dimensional spaces (Souravlas et al, 2021).

2.2. To display the network, using the proximity matrix as the network similarity matrix can describe the similarity relationship between the nodes in the network. But the relationship between nodes in a social network is complex. On the other hand, in addition to the similarity between nodes that are directly connected, there are different degrees of similarity between nodes that are not directly connected (Su et al., 2020).

2.3. Wu et al. (2020) and Geng et al. (2020) reconstructed the adjacency matrix to represent the network. Dhillon and Bhavani (2020) used a cubic matrix for the input of the stack autoencoders, as did the work of Yang et al. (2016). Xie et al. (2018) first proposed a new representation of network similarity and then fed it with a sparse filtering model to extract meaningful features of network nodes. But in addition to the problem of lack of neighbor information in the proximity matrix based on Su et al.'s (2020) research, using only one function to check the similarity between nodes cannot fully reveal the topological information of the network. Therefore, a similarity matrix should be presented that can solve the proposed gaps.

3. Methodology

In this paper, to reveal the direct and indirect connections among nodes, first, a new similarity matrix of network topology is built. To construct the new similarity matrix, two matrices are used, i.e. proximity matrix and Sørensen–Dice's (SØ) similarity matrix in Xie et al. (2018) 's research. In the next step to extract low-dimensional graph features, the new similarity matrix is given as input to the stack autoencoder networks, which have several hidden layers for unsupervised training. Then, using the newly learned features that are in the low-dimensional matrix with the help of K-means, DBSCAN, and SNNRPC clustering algorithms, communities are detected.


4. Conclusion


Evaluation of the proposed research model is performed by surveying various experiments on standard criteria and six real data sets of Karate, Dolphins, Football, Polbooks, Cora, and Citeseer. The proposed method evaluation outcomes show a higher accuracy in the detection of communities in the football data set compared to the twelve proposed algorithms used in past research and show a significant improvement in other data sets compared to the thirteen algorithms. In addition to these cases, the superiority of the similarity matrix used in this research was proved as a key prerequisite for community detection.

Keywords: Community Detection, Deep Learning, Autoencoder, Complex Networks.



تشخیص اجتماع در شبکه‌های اجتماعی با رویکرد یادگیری عمیق

منیره حسینی *  دانشیار گروه فناوری اطلاعات، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران، ایران

الناز گلوی  دانشجوی کارشناسی‌ارشد رشته مهندسی فناوری اطلاعات، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران، ایران

چکیده

تشخیص اجتماع یک موضوع مهم در تحلیل شبکه‌های اجتماعی می‌باشد و برای درک ساختار شبکه‌های پیچیده ضروری است. در تشخیص اجتماع هدف، شناسایی گروه‌هایی است که گره‌های گروه به‌طور متراکم باهم در ارتباط هستند. در این تحقیق، ضمن ارائه معماری جامع و یکپارچه‌ای از روش‌های تشخیص اجتماع با یادگیری عمیق، از تکنیک‌های یادگیری عمیق برای کنترل داده‌های گراف با ابعاد بالا استفاده شده است. روش‌های کلاسیک تشخیص اجتماع برای شبکه‌های با ابعاد پایین مناسب هستند. از این‌رو، کاهش ابعاد شبکه‌های پیچیده موضوع مهمی در تشخیص اجتماع به‌شمار می‌آید. در این تحقیق، ابتدا ماتریس شباهت جدیدی از توپولوژی شبکه برای آشکار کردن اتصالات مستقیم و غیرمستقیم بین گره‌ها ایجاد می‌شود. سپس یک خودمرزگذار پشته بر اساس یادگیری بدون نظارت برای کاهش ابعاد طراحی شده است. پس‌از آن الگوریتم‌های مختلف خوشه‌بندی تست و برای تشخیص اجتماعات به‌کاربرده می‌شوند. ارزیابی مدل پیشنهادی تحقیق، با انجام آزمایش‌های متعدد بر روی معیار استاندارد و شش مجموعه داده واقعی کاراته، دلفین‌ها، فوتبال، کتاب‌های سیاسی، کرا و شهروند مورد بررسی قرار می‌گیرد. نتایج ارزیابی روش پیشنهادی، در مجموعه داده فوتبال در مقایسه با دوازده الگوریتم مطرح به‌کاررفته در تحقیقات گذشته دقت بالاتری در شناسایی اجتماعات دارد و در سایر مجموعه داده‌ها در مقایسه با سیزده الگوریتم بهبود قابل توجهی را نشان می‌دهد.

کلیدواژه‌ها: تشخیص اجتماع، یادگیری عمیق، خودمرز گذار، شبکه‌های پیچیده.

مقاله حاضر برگرفته از پایان‌نامه کارشناسی‌ارشد رشته مهندسی فناوری اطلاعات دانشگاه صنعتی خواجه‌نصیرالدین طوسی است.

* نویسنده مسئول: hosseini@kntu.ac.ir

مقدمه

امروزه با توجه به گسترش روزافزون استفاده از اینترنت، شبکه‌های اجتماعی نقش مهمی در زندگی واقعی افراد پیدا کرده است و تعداد کاربران شبکه‌های اجتماعی به‌طور چشمگیری در حال افزایش است (روشنی و همکاران، ۱۳۹۲). تحلیل روابط در شبکه‌های اجتماعی بسیار حائز اهمیت است، زیرا با تحلیل شبکه‌های اجتماعی^۱ می‌توان به ارتباطات در این شبکه‌ها دست یافت. اطلاعات موجود در شبکه‌های اجتماعی از ارزش بسیاری برخوردارند و مبنای توسعه‌ی کسب‌وکارها هستند (روحانی و همکاران، ۱۳۹۶). هدف تحلیل شبکه اجتماعی کشف روابط بین موجودیت‌های اجتماعی و مشخص کردن ویژگی‌های کل شبکه است (Salehi & Pouyan, 2020).

تشخیص اجتماعات^۲ به ما اجازه می‌دهد تا شبکه‌های اجتماعی را تحلیل کنیم (Shchur & Gunnemann, 2019). در شبکه برخی گره‌ها در مقایسه با گره‌های دیگر شبکه، ارتباط بیشتری باهم دارند که به آن‌ها اجتماع گفته می‌شود (Sperli, 2019)؛ یعنی در تشخیص اجتماع می‌خواهیم شبکه را به چندین بخش به‌شدت متصل جدا کنیم (Xie et al., 2018). روش‌های تشخیص اجتماعات ابزاری ضروری برای درک ساختار و رفتار سیستم‌ها هستند (Shchur & Gunnemann, 2019). با استفاده از تشخیص اجتماع می‌توان ساختار شبکه را کشف کرد و اطلاعات مهم و اساسی را دریافت کرد (Xu et al., 2020). در واقع تشخیص و تمایز گروه‌هایی از کاربران که باهم ارتباطات تنگاتنگی دارند از اهمیت ویژه‌ای در مباحث تجاری، بازاریابی، انتخابات، شاخص سهام، علوم کامپیوتر، اهداف سیاسی و اجتماعی برخوردار است (قاسم پور و همکاران، ۱۳۹۲). پس شناسایی اجتماعات می‌تواند یک ارزش تحقیقاتی مهم و اهمیت علمی برای تحلیل ساختار شبکه فراهم کند (Xu et al., 2020).

رویکردهای بسیاری برای شناسایی اجتماع وجود دارد، اما با توجه به پیچیدگی مسئله تشخیص اجتماع و ضعف روش‌های پایه‌ای آن، مطالعات اخیر، به سمت روش‌های

1. Social networks analysis

2. Communities Detection

یادگیری عمیق^۱ هدایت شده است. تکنیک‌های یادگیری عمیق توجه محققان را برای پشتیبانی از کاربردهای مختلف (به‌عنوان مثال، تحلیل و درک تصویر، ترجمه خودکار ماشین و غیره) را به خود جلب کرده است و در ارتباط با مشکل تشخیص اجتماع، رویکردهای متعددی پیشنهاد داده است (Sperli, 2019). مزیت آشکار یادگیری عمیق برای تشخیص اجتماع نسبت به سایر روش‌های یادگیری ماشین^۲، توانایی آن برای رمزگذاری نمایش ویژگی‌های داده‌ها با ابعاد بالا است (Liu et al., 2020).

شبکه‌ها، روابط را به‌وسیله ساختار گراف با استفاده از رئوس و یال‌ها مدل می‌کنند (کوثری لنگری و همکاران، ۹۸). رویکردهای تشخیص اجتماع سنتی عمدتاً از گراف شبکه یک ماتریس مجاورت^۳ و یا یک ماتریس ویژگی گره می‌سازند (Yang et al., 2013؛ He et al., 2017؛ Liu et al., 2020). ماتریس مجاورت اطلاعات اتصالات مستقیم بین گره‌ها را ذخیره می‌کند و اتصالات غیرمستقیم بین گره‌ها را ذخیره نمی‌کند (Wu et al., 2020)؛ بنابراین در تشخیص اجتماع ابتدا باید یک ماتریس شباهت^۴ از توپولوژی شبکه برای آشکار کردن اتصالات مستقیم و غیرمستقیم بین گره‌ها ایجاد شود (Berahmand et al., 2018). سپس نمایشی کارآمد از ویژگی‌ها با ابعاد پایین به دست آید چون در حال حاضر، داده‌های شبکه‌های پیچیده ابعاد بالایی دارند. ایواننیکووا و همکاران^۵ (۲۰۱۸) توضیح دادند کاهش مؤثر بعد داده‌ها یکی از عوامل مهم برای افزایش دقت تشخیص اجتماع است. در آخرین گام باید به نتایج خوشه‌بندی^۶ دقیق‌تر برای تشخیص اجتماع دست یافت. الگوریتم خوشه‌بندی کا-میانگین^۷ به‌طور گسترده برای تقسیم شبکه‌های اجتماعی به کار می‌رود (Liu, 2010). با این حال، دقت نتایج پارتیشن‌بندی اجتماع بر اساس یک روش کلاسیک مانند الگوریتم خوشه‌بندی کا-میانگین خیلی بالا

-
1. Deep Learning
 2. Machine Learning
 3. Adjacency matrix
 4. Similarity Matrix
 5. Ivannikova et al.
 6. Clustering
 7. K-means

نیست (Xu et al., 2020). علاوه بر این در الگوریتم کا-میانگین باید تعداد خوشه‌ها از قبل مشخص باشد (شعار و سالار نژاد، ۱۳۹۷)؛ بنابراین، استفاده از الگوریتم‌های خوشه‌بندی دیگری ضروری است. برای پرداختن به مسائل ذکر شده در بالا، در این تحقیق بهبودهای متعددی برای افزایش دقت تشخیص اجتماع انجام می‌شود و یک چارچوب مناسب با انعطاف‌پذیری مدل برای شبکه‌های با اندازه‌های مختلف برای تشخیص اجتماع به کمک روش یادگیری عمیق پیشنهاد شده است.

سه نقش اصلی این تحقیق به شرح زیر است: ابتدا ماتریس شباهت جدیدی ساخته می‌شود که می‌تواند روابط مستقیم و غیرمستقیم شباهت بین گره‌های مختلف در توپولوژی شبکه را به طور کامل آشکار کند و باعث بهبود دقت تشخیص اجتماع می‌شود. سپس از خود رمزگذار پشته^۱ برای استخراج ویژگی‌ها با ابعاد پایین شبکه‌های پیچیده استفاده شده است. خود رمزگذار پشته یک شکل بسیار قدرتمند از مدل شبکه‌های عصبی عمیق^۲ برای تشخیص اجتماع است (Yang et al., 2016). پس از آن روش خوشه‌بندی جدیدی برای دستیابی به نتایج خوشه‌بندی با دقت بالا برای اولین بار در تشخیص اجتماعات استفاده شده است. علاوه بر این، چالش تعداد ناشناخته اجتماعات هم در این تحقیق حل شده است.

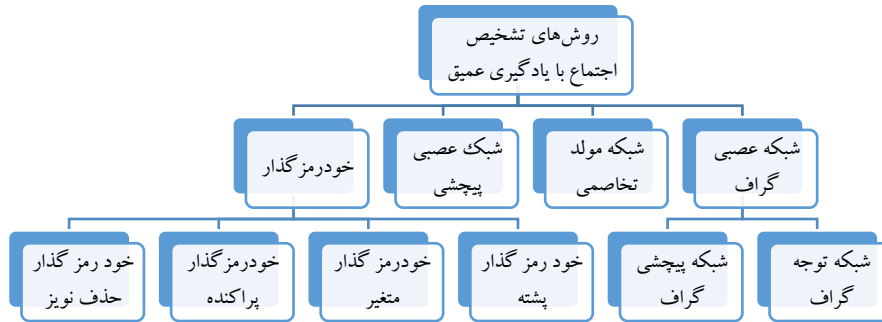
بقیه این تحقیق به شرح زیر سازمان‌دهی شده است. در بخش پیشینه پژوهش، کارهای تحقیقاتی مرتبط ارائه می‌شود. بخش روش، مدل تشخیص اجتماع پیشنهادی را توصیف می‌کند. نتایج تجربی در بخش یافته‌ها مورد بحث و ارزیابی قرار می‌گیرند. در نهایت بخش بحث و نتیجه‌گیری، این تحقیق را نتیجه‌گیری می‌کند.

پیشینه پژوهش

در این تحقیق مرور و بررسی جامعی بر روی ادبیات گذشته روش‌های تشخیص اجتماع با کمک یادگیری عمیق انجام شده است. دسته‌بندی روش‌های تشخیص اجتماع با یادگیری عمیق در شکل ۱ ارائه شده است.

-
1. Stacked auto-encoders
 2. Deep Neural Networks

شکل ۱. طبقه‌بندی روش‌های تشخیص اجتماع با یادگیری عمیق



جدول ۱ لیست مهم‌ترین تحقیقات ارائه‌شده تشخیص اجتماع با کمک روش‌های یادگیری عمیق را از نظر سال انتشار، روش یادگیری عمیق و استراتژی خاصی که برای تشخیص اجتماع استفاده می‌شود را خلاصه می‌کند.

جدول ۱. دسته‌بندی مقالات تشخیص اجتماع مبتنی بر یادگیری عمیق

دسته	نویسنده	سال	روش
خودرمزگذار پشته	یانگ و همکاران	۲۰۱۶	ایجاد یک مدل یادگیری عمیق با اتصال خود رمز گذارها به صورت سری برای بازسازی ماتریس پیمانه‌ای و اجرای خوشه‌بندی کا-میانگین
خودرمزگذار پشته	جین و همکاران	۲۰۱۷	ترکیب توپولوژی و محتوای گره به کمک خود رمز گذار پیش خور عمیق و خوشه‌بندی طیفی
شبکه عصبی پیچشی ^۱	شین و همکاران	۲۰۱۷	استفاده از شبکه عصبی پیچشی برای تشخیص اجتماع در شبکه‌های ناقص توپولوژیکی
خودرمزگذار	باهتیا و رانی	۲۰۱۸	ساختار لایه‌ای مبتنی بر خودرمزگذار، استفاده از گره کاندید و بهینه‌سازی با پیمانگی ^۲
خودرمزگذار پشته	وانگ و همکاران	۲۰۱۸	یک فرآیند تعبیه دو سطحی به کمک خودرمز گذار پشته و ماشین یادگیری شدید ^۳ بدون نظارت ^۴

1. Convolutional Neural Network (CNN)

2. Modularity

3. Extreme learning machine (ELM)

4. unsupervised learning

روش	سال	نویسنده	دسته
روش خود رمز گذار منظم بین دو نوع اطلاعات توپولوژیکی و محتوایی	۲۰۱۸	کائو و همکاران	خود رمز گذار پشته
روش مبتنی بر خود رمز گذار برای تشخیص اجتماع با استفاده از ترکیب پیشینه‌سازی پیمانگی و برش نرمال شده	۲۰۱۸	کائو و همکاران	خود رمز گذار پشته
استفاده از چارچوب یادگیری انتقال و تبدیل ماتریس مجاورت شبکه به شباهت	۲۰۱۹	شی و همکاران	خود رمز گذار پشته
استفاده از خود رمز گذار پشته و خوشه‌بندی کا میانگین	۲۰۱۹	وانگ و همکاران	خود رمز گذار پشته
معرفی دو تغییر قابل توجه در خود رمز گذار گراف متغیر برای تشخیص اجتماع	۲۰۱۹	چونگ و همکاران	خود رمز گذار متغیر ^۱
استفاده از ماتریس شباهت و خود رمز گذار برای بازسازی ماتریس، پیشنهاد فرمول بهینه‌سازی فاصله ویژگی	۲۰۱۹	لی و همکاران	خود رمز گذار
استفاده از دو مرحله کانولوشن برای یادگیری توپولوژی شبکه ورودی، به‌علاوه لایه اتصال کامل برای اصلاح نتایج	۲۰۱۹	اسپرلی	شبکه عصبی پیچشی
تشخیص اجتماع همپوشان به کمک ترکیب گراف مدل وابستگی و شبکه‌های مولد تخصصی، تولید محتمل‌ترین نقوش با آگاهی از ساختار گراف	۲۰۱۹	جیا و همکاران	شبکه مولد تخصصی ^۲
استفاده از شبکه‌های عصبی گراف در یک محیط یادگیری با نظارت و معرفی یک عملگر غیر عقب‌گرد برای تعریف مجاورت	۲۰۱۹	چن و همکاران	شبکه عصبی گراف ^۳
ترکیب محتوا و توپولوژی و استفاده از میدان تصادفی مارکوف به‌عنوان لایه کانولوشن جدید	۲۰۱۹	جین و همکاران	شبکه پیچشی گراف
تشخیص اجتماع همپوشان به کمک ترکیب مدل احتمالی برنولی - پواسون و شبکه پیچشی گراف	۲۰۱۹	شوچرو گوننمان	شبکه عصبی گراف
استفاده از همسایگان درجه بالا برای خوشه‌بندی	۲۰۱۹	وانگ و همکاران	شبکه توجه گراف

1. Variational Autoencoders
2. Generative Adversarial Network (GAN)
3. Graph Neural Networks (GNN)

دسته	نویسنده	سال	روش
			اجتماعات تحت آموزش
خودرمز گذار پشته	شو و همکاران	۲۰۲۰	استفاده از ۴ تابع برای ماتریس شباهت، ترکیب یادگیری انتقال و خودرمز گذار پشته سپس اجرای خوشه‌بندی گروهی
خودرمز گذار پشته	دیلبز و بهاوانی	۲۰۲۰	چندین خودرمز گذار را برای کاهش ابعاد تعبیه کرده و اشتراک گذاری پارامتر را اعمال می‌کند
خودرمز گذار پشته	صالحی و پویان	۲۰۲۰	رمز گذار پشته آموزش داده می‌شود و به یک الگوریتم خوشه‌بندی همپوشان اعمال می‌گردد
خودرمز گذار پراکنده ^۱	فی و همکاران	۲۰۲۰	ماتریس شباهت و بازسازی با خود رمز گذار پراکنده عمیق
خودرمز گذار حذف نویز ^۲	گنگ و همکاران	۲۰۲۰	استفاده از ماتریس انتقال احتمال، خود رمز گذار و گام تصادفی
شبکه عصبی پیچشی	کای و همکاران	۲۰۲۰	یک مدل تبدیل یال به تصویر (نگاشت ساختار شبکه یال به ساختار تصویر) و استفاده از مدل شبکه عصبی پیچشی برای طبقه‌بندی یال
خود رمز گذار و شبکه عصبی پیچشی	وو و همکاران	۲۰۲۰	استخراج ویژگی مکانی و بازسازی با خود رمز گذار و شبکه عصبی پیچشی
شبکه مولد تخصصی	ژانگ و همکاران	۲۰۲۰	گسترش دانه با یادگیری متخاصم مولد
خودرمز گذار پشته	الاندولی و همکاران	۲۰۲۱	پارتیشن‌بندی شبکه، کاهش و به اشتراک گذاری پارامترهای آموزش پذیر
شبکه پیچشی گراف	هی و همکاران	۲۰۲۱	گسترش شبکه‌های پیچشی گراف و میدان تصادفی به‌عنوان خود رمز گذار
خودرمز گذار توجه	گو و همکاران	۲۰۲۲	افزودن لایه‌ی توجه به خودرمز گذار و استفاده از استراتژی پیاده‌روی تصادفی
خودرمز گذار پشته	حسینی و گلوی	۲۰۲۲	استفاده از دو تابع برای ایجاد ماتریس شباهت جدید، ایجاد مدل خودرمز گذار پشته برای کاهش ابعاد و سپس اجرا و مقایسه سه روش خوشه‌بندی

1. Sparse auto Autoencoder
2. Denoising Auto-encoder (DAE)

در سال‌های اخیر، یادگیری عمیق عملکرد برجسته‌ای را در طیف گسترده‌ای از زمینه‌های تحقیقاتی، مانند شبکه‌های اجتماعی و تعبیه گراف نشان داده است (Wu et al., 2020). تعبیه گراف^۱ یک روش مؤثر برای تبدیل داده‌های گراف به یک فضای کم بعدی است (Wu et al., 2020). تعبیه گراف عمیق تکنیکی است که گره‌های موجود در شبکه را به یک فضای بردار کم بعدی نگاشت می‌کند، ضمن اینکه اطلاعات ساختاری را تا حد امکان در بازنمایی‌ها ذخیره می‌کند. پس‌از آن، روش‌های خوشه‌بندی مانند کا-میانگین می‌توانند از شناسایی اجتماع حمایت کنند (Liu et al., 2020).

برای استخراج ویژگی‌ها در ابعاد پایین مطابق جدول ۱ در مطالعات اخیر دریافتیم خودمرزگذارها به دلیل توانایی آن‌ها در نمایش شبکه‌های دنیای واقعی غیرخطی در تشخیص اجتماع بسیار رایج هستند. خودمرزگذارها مبتنی بر شبکه عصبی عمیق برای یادگیری بازنمایی مجموعه داده‌ها به شیوه‌ای بدون نظارت استفاده می‌شوند. آن‌ها ابزاری برای کاهش ابعاد هستند؛ بنابراین خودمرزگذار برای نگاشت نقاط داده در فضای ابعاد کم مناسب است که در تشخیص اجتماع مورد نیاز است (Souravlas et al., 2021).

در تحقیقات یانگ و همکاران (۲۰۱۶)، دیلبر و بهاوانی (۲۰۲۰)، شی و همکاران (۲۰۱۸)، شی و همکاران (۲۰۱۹)، وو و همکاران (۲۰۲۰)، یه و همکاران (۲۰۱۸)، گنگ و همکاران (۲۰۲۰) و صالحی و پویان (۲۰۲۰) اطلاعات شباهت بین گره‌های شبکه به کمک روش‌های یادگیری عمیق نگاشت می‌شود سپس اجتماعات با اجرای روش‌های خوشه‌بندی شناسایی می‌شوند.

برای نمایش شبکه استفاده از ماتریس مجاورت به‌عنوان ماتریس شباهت شبکه می‌تواند رابطه شباهت بین گره‌ها در شبکه را توصیف کند؛ اما رابطه بین گره‌ها در یک شبکه اجتماعی پیچیده است. از سوی دیگر، علاوه بر شباهت بین گره‌هایی که به‌طور مستقیم متصل شده، درجات مختلفی از شباهت بین گره‌هایی وجود دارد که به‌طور مستقیم متصل نیستند (Xu et al., 2020).

وو و همکاران (۲۰۲۰) و گنگ و همکاران (۲۰۲۰) برای نمایش شبکه، ماتریس مجاورت را بازسازی کردند. دیلبر و بهاوانی^۱ (۲۰۲۰) مانند کار یانگ و همکاران^۲ (۲۰۱۶) از ماتریس پیمانهای برای ورودی خودرمزگذار پشته استفاده کردند. شی و همکاران^۳ (۲۰۱۸) ابتدا نمایش جدیدی از شباهت شبکه را پیشنهاد کردند و سپس آن را با یک مدل فیلترینگ پراکنده تغذیه کردند تا ویژگی‌های معنی‌دار گره‌های شبکه را استخراج کنند؛ اما علاوه بر مشکل کمبود اطلاعات همسایه در ماتریس مجاورت (Wu et al., 2020) بر اساس تحقیق شو و همکاران (۲۰۲۰) استفاده از فقط یک تابع برای بررسی شباهت بین گره‌ها نمی‌تواند به‌طور کامل اطلاعات توپولوژیکی شبکه را آشکارا سازد؛ بنابراین باید ماتریس شباهتی ارائه شود که بتواند شکاف‌های مطرح‌شده را حل کند.


لیو و همکاران^۴ (۲۰۲۰) یکی دیگر از چالش‌های مسئله تشخیص اجتماع را تعداد ناشناخته اجتماعات معرفی کردند. باوجود برخی راه‌حل‌های حرفه‌ای، این مشکل هنوز به‌طور کامل برطرف نشده است (Liu et al., 2020).

روش

طرح پیشنهادی این تحقیق مطابق شکل ۲ انجام می‌شود. ابتدا یک نمایش ماتریسی از گراف شبکه به‌دست آمده که از ترکیب ماتریس مجاورت و ماتریس شباهت سورنس-دایس در تحقیق شی و همکاران (۲۰۱۸) استفاده شده است. در گام بعد ماتریس شباهت را به‌عنوان ورودی به شبکه‌های خودرمزگذار پشته می‌دهیم که دارای چندین لایه پنهان برای آموزش نظارت نشده هستند، اکنون ابعاد پایین گراف استخراج شده است. در گام بعدی با استفاده از ویژگی‌های تازه آموخته شده که در ماتریس با ابعاد پایین قرار دارد به کمک الگوریتم‌های خوشه‌بندی اجتماعات تشخیص داده می‌شود.

-
1. Dhillber & bhavani
 2. Yang et al
 3. Xie et al
 4. Liu et al

شکل ۲. چارچوب مدل پیشنهادی تحقیق (CDDL)



ساخت ماتریس شباهت SA

به منظور پیدا کردن یک پارتیشن دقیق از یک شبکه، نمایش مؤثر شبکه ضروری است. پس ماتریس شباهت از اهمیت زیادی برخوردار است. گره‌ها در شبکه‌های پیچیده تمایل دارند ویژگی‌های اجتماع را نشان دهند و تشخیص اجتماع گره‌های مشابه را به یک اجتماع تقسیم می‌کند (Xie et al., 2018).

در ماتریس مجاورت اگر بین دو گره به طور مستقیم یال وجود باشد مقدار یک برای آن درایه در نظر گرفته می‌شود و اگر بین دو گره به طور مستقیم یالی وجود نداشته باشد مقدار صفر در نظر گرفته می‌شود. اگر دو گره بین آن‌ها به طور مستقیم یال باشد احتمال اینکه در یک اجتماع قرار بگیرند بالا است. از طرفی برای هر دو گره در اجتماع، حتی اگر به یکدیگر به طور مستقیم متصل نباشند، باز هم داشتن یک اجتماع ممکن است (Fei et al., 2020). پس ماتریس مجاورت مشکلات کمبود اطلاعات همسایه دارد (Wu et al., 2020). علاوه بر این ماتریس شباهت با یک تابع تنها نمی‌تواند به طور مؤثر روابط شباهت بین گره‌ها در توپولوژی شبکه را نشان دهد (Xu et al., 2020).

در این تحقیق از ترکیب دو ماتریس استفاده می‌شود یعنی ماتریس مجاورت را با ماتریس شباهت سورنسن-دایس در تحقیقی و همکاران (۲۰۱۸) ترکیب می‌کنیم و ماتریس شباهتی جدیدی به دست می‌آوریم تا مشکلات مطرح شده را حل کند. ابتدا هر دو ماتریس مجاورت و سورنسن-دایس را از گراف شبکه به دست می‌آوریم سپس برای گره‌هایی که به طور مستقیم به هم متصل هستند مقدار یک و برای گره‌هایی که به طور

مستقیم بین آن‌ها یالی وجود ندارد از شباهت سورنسن-دایس) استفاده شده چون اطلاعات محلی و همسایگان گره‌ها را منعکس می‌کند و مشکل ماتریس مجاورت را برای گره‌هایی که به طور مستقیم متصل نیستند را می‌تواند حل کند. در تحقیقی و همکاران (۲۰۱۸) شباهت سورنسن-دایس با سه ماتریس مجاورت، پیمان‌های و ماتریس شباهت نرمال شده مقایسه شد و برتری ماتریس شباهت سورنسن-دایس را نشان داده است؛ بنابراین استفاده از این ماتریس دقت تشخیص اجتماع را بهبود می‌بخشد. شباهت سورنسن-دایس بین دو گره v_i و v_j مطابق رابطه ۱ تعریف می‌شود:

$$S_{\emptyset} = \frac{2\text{CommonNeighbors}(v_i, v_j)}{d(v_i) + d(v_j)} \quad (1)$$

عدد $\text{CommonNeighbors}(v_i, v_j)$ به تعداد گره‌های همسایه مشترک بین دو گره v_i و v_j اشاره دارد؛ و مخرج $d(v_i) + d(v_j)$ مجموع درجه گره‌های i و j را نشان می‌دهد.

خودرمز گذار پشته برای کاهش ابعاد

کاهش ابعاد ویژگی در تشخیص اجتماع یک موضوع تحقیقاتی مهم در شبکه‌های پیچیده است (Fie et al., 2020). خودرمز گذار برای نگاشت نقاط داده در فضای ابعاد کم مناسب است (Souravlas et al., 2021). بر اساس تحقیق ال‌اندولی و همکاران^۱ (۲۰۲۱) روش خودرمز گذار پشته بیشترین کارایی را بین انواع خودرمز گذارها در مسئله تشخیص اجتماع دارد؛ بنابراین برای نگاشت ویژگی‌ها در ابعاد پایین از مدل خودرمز گذار پشته استفاده می‌کنیم.

یک خودرمز گذار یک معماری شبکه عصبی عمیق متشکل از رمز گذار و رمز گشا است. بخش رمز گذار داده‌ها را به ابعاد پایین‌تر فشرده می‌کند تا حداکثر اطلاعات را حفظ کند. در طرف دیگر، رمز گشا رمز فشرده را گسترش می‌دهد تا خروجی را با حداکثر شباهت به عنوان ورودی تولید کند. شکل ۳ یک شبکه خود رمز گذار را نشان می‌دهد.

1. Al-Andoli et al

همان‌طور که می‌بینید شبکه در جهتی آموزش می‌بیند که وزن‌های تولید شده در لایه‌ها، باعث شود خروجی با ورودی حداقل اختلاف ممکن را داشته باشد. رمزکننده‌های خودکار از الگوریتم پس انتشار برای یادگیری وزن‌ها استفاده می‌کنند. برای بازسازی، مقادیر هدف مانند مقادیر ورودی تنظیم می‌شوند و خطا به صورت برگشتی منتشر می‌شود. با در نظر گرفتن ماتریس شباهت ورودی $SA = [sa_{ij}]$ ، sa_i رأس را در ستون i نشان می‌دهد. در طرف رمزگذار در رابطه ۲ داریم:


$$e_i = a(W_E sa_i + d_E) \quad (2)$$

که در آن WE و dE وزن‌های شبکه عصبی هستند که باید یاد گرفته شوند، sa_i ورودی و a تابع فعال‌سازی است. در طرف رمزگشا در رابطه ۳ داریم:

$$d_i = a(W_D e_i + d_D) \quad (3)$$

که در آن WD و dD پارامترها هستند، e_i ورودی کد شده و a تابع فعال‌سازی دیگری است (Dhilber & bhavani, 2020; Xu et al., 2020).

شکل ۳- ساختار خودرمزگذار



برای ایجاد خودرمزگذار پشته، خود رمزگذارها روی هم قرار داده می‌شوند. مدل خود رمزگذار پشته با لایه‌های متفاوت بسته به مجموعه داده‌ها ساخته می‌شود. سپس ماتریس

شباهتی که در مرحله قبل به دست آوردیم را به عنوان ورودی خودرمز گذار پشته استفاده می‌کنیم تا ویژگی‌ها با ابعاد پایین استخراج شود و یک نمایش کم بعدی از شبکه متناظر به دست می‌آید. انتظار می‌رود که شبکه بازسازی شده ساختارهای پنهان شبکه اصلی را بهتر نشان دهد.

روش خوشه‌بندی و شناسایی اجتماعات

اکنون باید با استفاده از الگوریتم‌های خوشه‌بندی اجتماعات را شناسایی کنیم. چون هیچ الگوریتم خوشه‌بندی واحدی وجود ندارد که بتواند بهترین پارتیشن‌بندی را در تمام مجموعه داده‌ها پیدا کند (Xu et al., 2020). برای شناسایی اجتماعات با دقت بالا از سه روش خوشه‌بندی در این تحقیق استفاده می‌کنیم. تشخیص اجتماع با استفاده از الگوریتم‌های خوشه‌بندی کا-میانگین، «خوشه‌بندی مبتنی بر نزدیک‌ترین همسایه با جستجوی سریع و یافتن قله‌های چگالی مشترک^۱» و «خوشه‌بندی فضایی مبتنی بر چگالی در کاربردهای دارای نویز^۲» برای نمایش به دست آمده انجام می‌شود. الگوریتم خوشه‌بندی SNNDPC چگالی هر نقطه را بر اساس الگوریتم نزدیک‌ترین همسایه مشترک به دست می‌آورد (Liu et al., 2018). برای اولین بار در این تحقیق از خوشه‌بندی SNNDPC برای تشخیص اجتماع استفاده شده است.

یافته‌ها

ابزار پیاده‌سازی

برای اجرای این تحقیق از زبان برنامه‌نویسی پایتون^۳ و از کراس^۴ به عنوان کتابخانه یادگیری عمیق استفاده شده است. برای تابع بهینه‌ساز از آدام^۵ و برای تابع فعال‌ساز بسته به مجموعه

1. Shared Nearest Neighbor-based Clustering by Fast Search and Find of Density Peaks(SNNDPC)
2. Density-based spatial clustering of applications with noise (DBSCAN)
3. Python
4. Keras
5. Adam

داده‌ها از رلو^۱ یا سیگموئید^۲ استفاده شده است. از آنتروپی سیگموئید - کراس^۳ به عنوان تابع زیان^۴ استفاده شده است. برای اجرای خوشه بند DBSCAN از روش بروت-فورس^۵ استفاده شده است تا بهترین پارامترها برای الگوریتم به دست آید.

مجموعه داده‌ها

مدل بر روی شش شبکه واقعی تحلیل شده است. شبکه باشگاه کاراته زاخاری^۶ که یکی از شبکه‌های رایج مورد استفاده در ارزیابی اجتماع است. شامل دو خوشه و ۳۴ عضو است (Zachary, 1977). شبکه دلفین‌ها^۷ از ۶۲ عضو دلفین‌های پوزه بطری با مشاهده رفتار دلفین‌ها به مدت ۷ سال ایجاد شده است که به دو گروه تقسیم می‌شوند (Lusseau & Newman, 2004). کتاب‌های سیاست آمریکا^۸ متشکل از ۱۰۵ گره و ۴۴۱ رابطه بین گره‌ها است که به ۳ گروه تقسیم می‌شوند (Newman, 2006). شبکه فوتبال کالج آمریکا^۹ شامل ۱۱۵ عضو و ۱۲ بخش است از بازی‌های فوتبال آمریکایی توسط گیروان و نیومن گردآوری شده است (Girvan & Newman, 2002). شبکه کرا^{۱۰} یک شبکه زیرمجموعه از مجموعه داده استنادی بزرگ‌تر کرا است، این مجموعه داده شامل نشریاتی از حوزه یادگیری ماشین است که شامل ۲۷۰۸ نشریه است و به ۷ زیر مجموعه طبقه‌بندی می‌شوند (Yang et al., 2009). مجموعه داده شبکه شهروند^{۱۱} متشکل از ۳۳۱۲ نشریه علمی طبقه‌بندی شده به ۶ اجتماع است (Yang et al., 2009).
تعداد گره‌ها، یال‌ها و اجتماعات شبکه‌ها در جدول ۲ فهرست شده است.

1. Relu
2. Sigmoid
3. sigmoid-cross entropy
4. Loss
5. brute-force
6. Zakhary Karate Club
7. Dolphins
8. United States Political Books (PolBooks)
9. Football Club
10. Cora
11. Citeseer

جدول ۲- اطلاعات مجموعه داده‌ها

تعداد اجتماعات	تعداد یال‌ها	تعداد گره‌ها	مجموعه داده
۲	۷۸	۳۴	کارانه
۲	۱۵۹	۶۲	دلفین‌ها
۱۲	۶۱۳	۱۱۵	فوتبال
۳	۴۴۱	۱۰۵	کتاب‌های سیاسی
۷	۵۴۲۹	۲۷۰۸	کرا
۶	۴۷۳۲	۳۳۱۲	شهروند

معیار اطلاعات متقابل نرمال شده

معیارهای زیادی برای ارزیابی کیفیت اجتماعات وجود دارد اما بر اساس تحقیق سو و همکاران^۱ (۲۰۲۱) در این تحقیق از معیار اطلاعات متقابل نرمال شده^۲ استفاده شده است. برای کار تشخیص اجتماع در تعداد بیشتری از مقالات معتبر استفاده شده است. این معیار میزان دقت الگوریتم‌ها را در شناسایی اجتماعات باکیفیت و درست از یک شبکه موردسنجش قرار می‌دهد. میزان تشابه اجتماعات شناسایی شده توسط یک الگوریتم را با اجتماعات حقیقی یک شبکه اندازه‌گیری می‌کند (حسینیان و همکاران، ۱۳۹۸).

در این معیار مقدار اندازه‌گیری کیفیت بین صفر و یک است که نشان می‌دهد دو خوشه در چه همبستگی قرار دارند. مقدار صفر هیچ اطلاعات متقابلی را نشان نمی‌دهد و مقدار یک همبستگی کامل را نشان می‌دهد. مقدار تابع اطلاعات متقابل نرمال شده را می‌توان از رابطه (۴) به دست آورد.

$$NMI(A, B) = \frac{-2 \sum_{i=1}^{C_A} \sum_{j=1}^{C_B} C_{ij} \log(C_{ij}/C_i C_j)}{\sum_{i=1}^{C_A} C_i \log(C_i/n) + \sum_{j=1}^{C_B} C_j \log(C_j/n)} \quad (4)$$

1. Su et al.

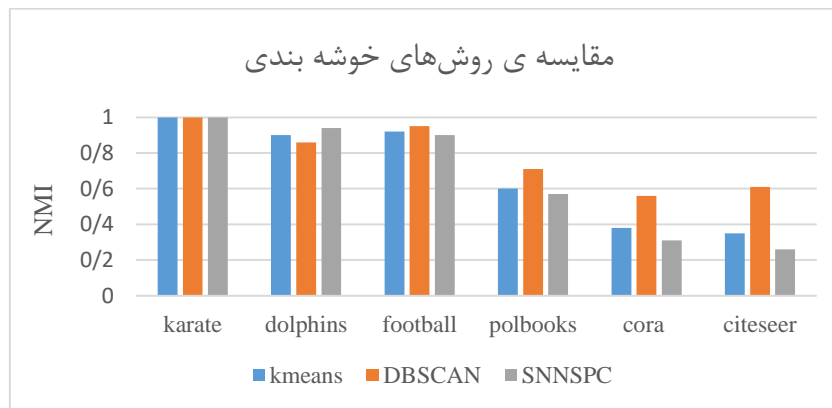
2. Normalized Mutual Information (NMI)

C_A تعداد گروه‌های موجود در پارتیشن‌بندی A است. C_B تعداد گروه‌های موجود در پارتیشن‌بندی B است. C_i (مجموع عناصر C_j) در ردیف i th (ستون j th) است و n تعداد گره‌ها است. اگر $A = B$ ، $NMI(A, B) = 1$ و اگر A و B کاملاً متفاوت باشند، $NMI(A, B) = 0$ است (Xie et al., 2018).

نتایج

سه روش خوشه‌بندی روی مدل اجرا می‌شود و نتایج بر اساس معیار NMI مطابق شکل ۴ مشاهده می‌شود. به جز مجموعه داده دلفین که روش خوشه‌بندی $SNNDPC$ بیشترین دقت را دارد برای سایر مجموعه داده‌ها روش خوشه‌بندی $DBSCAN$ با بیشترین دقت اجتماعات را شناسایی می‌کند. از طرفی روش خوشه‌بندی $DBSCAN$ مشکل تعداد نامشخص اجتماعات را حل می‌کند چون برای اجرا، الگوریتم‌های خوشه‌بندی k -میانگین و $SNNDPC$ باید تعداد نهایی خوشه‌ها را از قبل بدانند اما در روش خوشه‌بندی $DBSCAN$ نیاز نداریم تعداد خوشه‌ها را از قبل بدانیم.

شکل ۴. مقایسه بین عملکرد NMI با روش‌های خوشه‌بندی k -means، $DBSCAN$ و $SNNDPC$ در ۶ مجموعه داده‌های دنیای واقعی



مقایسه مدل‌ها

نتایج NMI به‌دست آمده توسط مدل پیشنهادی با سیزده الگوریتم مقایسه شده است. الگوریتم FN (Newman, 2004)، الگوریتم FUA (Blondel et al., 2008)، الگوریتم

SP (Newman, 2006)، الگوریتم YASCA (Kanawati & Rushed., 2014)، الگوریتم EO (Duch & Arenas, 2005)، الگوریتم SSCF (Mahmood & Small, 2014)، الگوریتم Jin's NM (Liu et al., 2014)، الگوریتم DAEM (Dhilber & Tian et al., 2020)، الگوریتم DANMF (Ye et al., 2018)، الگوریتم SPAE (bhavani, 2020)، الگوریتم DNR (Yang et al., 2016)، الگوریتم DACDRP (Al-Andoli et al., 2021) و الگوریتم DSFCD (Xie et al., 2018).

الگوریتم‌های FN، FUA، SP، EO روش‌های مبتنی بر پیمانی هستند. Jin's NMF از یک روش فاکتورگیری نامنفی ماتریس^۱ بر اساس پارته‌شن‌های گره و یال مرتبط استفاده می‌کند. DNR از یک مدل غیرخطی در شبکه‌های عصبی عمیق برای تشخیص اجتماع استفاده می‌کند. SSCF یک روش تشخیص اجتماع زیرفضای پراکنده بر اساس رمزگذار خطی پراکنده است. YASCA یک رویکرد مجموعه‌ای برای تشخیص اجتماع در شبکه‌های پیچیده است. DAEM از خودرمزگذار پشته و از اشتراک‌گذاری وزن بین لایه‌ها استفاده کرد. SPAE از خودرمزگذار پراکنده برای خوشه‌بندی گراف استفاده می‌کند. DANMF روش فاکتورگیری نامنفی ماتریس مبتنی بر خودرمزگذار پشته برای حل مشکل تشخیص اجتماع پیشنهاد کرد. DACDRP از خودرمزگذار پشته و ماتریس شباهت سورنس-دایس استفاده می‌کند و به کمک پارته‌شن‌بندی شبکه پارامترهای آموزش پذیر را کاهش می‌دهد. در روش DSFCD نمایش کارآمد از شبکه با ماتریس شباهت سورنس-دایس به دست می‌آید سپس ویژگی‌های شبکه با فیلتر پراکنده استخراج می‌شود.

برای ارزیابی مدل پیشنهادی روش‌ها جهت مقایسه به نحوی انتخاب شدند تا بتوانند طیف وسیعی از تحقیقات شناسایی اجتماعات را پوشش دهند. از شکل ۵، می‌توان مشاهده کرد که مدل پیشنهادی بر اساس معیار NMI بهبود قابل‌توجهی نسبت به دیگر الگوریتم‌های موجود دارد به‌طور مثال در مجموعه داده شهروند، روش تحقیق حاضر از


1. Matrix factorization non negative

بهترین الگوریتم موجود میزان ۲۳ درصد بهبود داشته است. همچنین مقایسه با تحقیقات DSFCD و DADDRP که از ماتریس شباهت سورنسن-دایس به‌تنهایی برای شباهت استفاده می‌کنند برتری ماتریس شباهت مورد استفاده در این تحقیق را ثابت می‌کند؛ بنابراین، روش تشخیص اجتماع پیشنهادی می‌تواند به‌طور مؤثری اجتماعات با کیفیت بالا را در شبکه‌های اجتماعی شناسایی کند.


شکل ۵. مقایسه عملکرد NMI بین مدل پیشنهادی تحقیق (CDDL) و الگوریتم‌های تشخیص



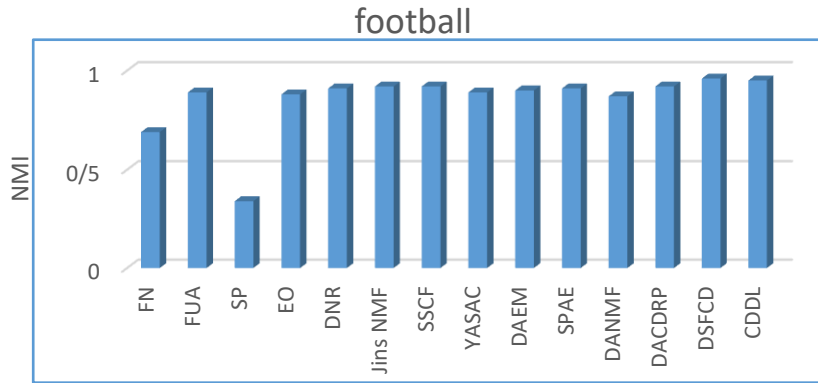
اجتماع موجود

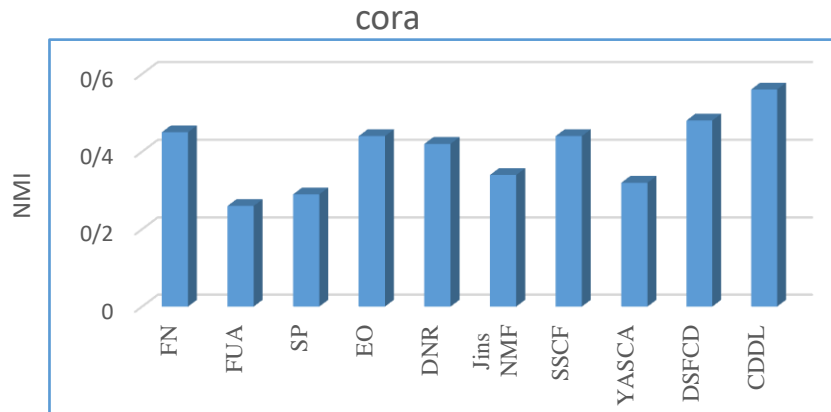
dolphine



karate







بحث و نتیجه‌گیری

در این تحقیق، برای تشخیص اجتماعات در شبکه‌ها یک روش بهبودیافته پیشنهاد شده است که به شناسایی ساختار شبکه کمک می‌کند. ماتریس شباهت جدیدی پیشنهاد شد که از دو تابع برای شباهت بین گره‌ها استفاده می‌کند تا رابطه بین گره‌ها در شبکه پیچیده را به‌طور کامل توصیف کند. سپس یک خود رمز گذار پشته استفاده شده است تا نمایش مؤثرتری از ویژگی‌های کم بعدی به دست آید. در نهایت، برای بهبود دقت خوشه‌بندی، سه روش خوشه‌بندی تست شد که با دقت بالا اجتماعات را شناسایی کردند. آزمایش‌ها بر روی مجموعه داده‌ها نشان داده است که مدل پیشنهادی بر اساس معیار NMI بهبود قابل توجهی در مقایسه با دیگر روش‌های موجود در تشخیص اجتماع دارد. این تحقیق وضعیت همپوشانی اجتماع را در نظر نمی‌گیرد؛ بنابراین، تشخیص اجتماع در شبکه‌های همپوشانی جهت تحقیقات آینده مورد بررسی قرار خواهد گرفت. علاوه بر این محاسبه ماتریس شباهت با اندازه شبکه افزایش می‌یابد که منجر به مصرف حافظه زیاد می‌شود. گسترش مدل برای مجموعه داده‌های بزرگ‌تر و استفاده از استراتژی تجزیه برای ماتریس بزرگ در محاسبه شباهت باید در مطالعات آینده مورد انتظار باشد.

تعارض منافع

تعارض منافع ندارم.

ORCID

Monireh Hoseini



<http://orcid.org/0000-0002-3677-0811>

Elnaz Galavi



<http://orcid.org/0009-0001-0573-1924>

منابع

- حسینیان، امیرحسین، تیموریور، بابک و جمالی هندی، باقر. (۱۳۹۸). توسعه یک روش فرا ابتکاری ترکیبی برای شناسایی اجتماعات در شبکه‌های اجتماعی باهدف چگالی پودمانگی. *مطالعات مدیریت کسب‌وکار هوشمند*. ۸(۲۹). ۶۱-۸۶. doi: 10.22054/ims.2019.10376
- روحانی، سعید، امیریان، سمانه و محمدیان، ایوب. (۱۳۹۶). شناسایی و اولویت‌بندی کاربردهای شبکه کاوی در تجارت الکترونیکی. *مطالعات مدیریت کسب‌وکار هوشمند*. ۶(۲۱). ۱-۳۲. doi: 10.22054/ims.2018.8510
- روشنی، سعید، رضایی نیک، نفیسه و شجاعی، سید محمدحسین. (۱۳۹۲). مطالعه مقایسه‌ای قابلیت سازی و جامعه‌پذیری شبکه‌های اجتماعی عمومی و تخصصی. *مطالعات مدیریت کسب‌وکار هوشمند*. ۸(۵). ۹۷-۱۳۲.
- شعار، مریم و سالارنژاد، علی‌اصغر. (۱۳۹۷). روشی جدید برای خوشه‌بندی اسناد HTML با استفاده از الگوریتم‌های تلفیقی. *مطالعات مدیریت کسب‌وکار هوشمند*. ۶(۲۴). ۳۷-۶۲. doi: 10.22054/ims.2018.8891
- کوثری لنگری، روح‌الله، سردار، سهیلا، امین موسوی، سید عبدالله و رادفر، رضا. (۱۳۹۸). مدلی برای انتشار داده‌های شبکه‌های اجتماعی برخط با حفظ حریم خصوصی. *مطالعات مدیریت کسب‌وکار هوشمند*. ۸(۲۹). ۸۷-۱۱۲. doi: 10.22054/ims.2019.10377
- قاسم پور، محدثه، سیفی، عباس و علیزاده، حسین. (۱۳۹۲). تشخیص اجتماعات در شبکه‌های اجتماعی، دومین کنفرانس ملی مهندسی صنایع و سیستم‌ها، اصفهان، <https://civilica.com/doc/251290>

References

- Al-Andoli, M., Cheah, W. P., & Tan, S. C. (2021). Deep learning-based community detection in complex networks with network partitioning and reduction of trainable parameters. *Journal of Ambient Intelligence and Humanized Computing*, 12 (2), 2527-2545.
- Al-Andoli, M. N., Tan, S. C., Cheah, W. P., & Tan, S. Y. (2021). A Review on Community Detection in Large Complex Networks from Conventional to Deep Learning Methods: A Call for the Use of Parallel Meta-Heuristic Algorithms. *IEEE Access*, 9, 96501-96527.

- Bhatia, V., & Rani, R. (2019). A distributed overlapping community detection model for large graphs using autoencoder. *Future Generation Computer Systems*, 94, 16-26.
- Berahmand, K., Bouyer, A., & Vasighi, M. (2018). Community detection in complex networks by detecting and expanding core nodes through extended local similarity of nodes. *IEEE Transactions on Computational Social Systems*, 5(4), 1021-1033.
- 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*, 2008 (10), P10008.
- Cai, B., Wang, Y., Zeng, L., Hu, Y., & Li, H. (2020). Edge classification based on convolutional neural networks for community detection in complex network. *Physica A: Statistical Mechanics and its Applications*, 556, 124826.
- Cao, J., Jin, D., & Dang, J. (2018, August). Autoencoder based community detection with adaptive integration of network topology and node contents. In *International conference on knowledge science, engineering and management* (pp. 184-196). Springer, Cham.
- Cao, J., Jin, D., Yang, L., & Dang, J. (2018). Incorporating network structure with node contents for community detection on large networks using deep learning. *Neurocomputing*, 297, 71-81.
- Chen, Z., Li, X., & Bruna, J. (2019). Supervised community detection with line graph neural networks. *arXiv preprint arXiv:1705.08415*.
- Choong, J. J., Liu, X., & Murata, T. (2019, December). Optimizing variational graph autoencoder for community detection. In *2019 IEEE International Conference on Big Data (Big Data)* (pp. 5353-5358). IEEE.
- Dhilber, M., & Bhavani, S. D. (2020, January). Community detection in social networks using deep learning. In *International conference on distributed computing and internet technology* (pp. 241-250). Springer, Cham.
- Duch, J., & Arenas, A. (2005). Community detection in complex networks using extremal optimization. *Physical review E*, 72(2), 027104.
- Fei, R., Sha, J., Xu, Q., Hu, B., Wang, K., & Li, S. (2020). A new deep sparse autoencoder for community detection in complex networks. *EURASIP Journal on Wireless Communications and Networking*, 2020 (1), 1-25.
- Geng, X., Lu, H., & Sun, J. (2020). Network structural transformation-based community detection with autoencoder. *Symmetry*, 12 (6), 944.
- Girvan, M., & Newman, M. E. (2002). Community structure in social and biological networks. *Proceedings of the national academy of sciences*, 99(12), 7821-7826.

- Guo, K., Zhang, P., Guo, W., & Chen, Y. (2022). An attentional-walk-based autoencoder for community detection. *Applied Intelligence*, 1-19.
- He, D., Feng, Z., Jin, D., Wang, X., & Zhang, W. (2017, February). Joint identification of network communities and semantics via integrative modeling of network topologies and node contents. In *Thirty-First AAAI Conference on Artificial Intelligence*.
- He, D., Song, Y., Jin, D., Feng, Z., Zhang, B., Yu, Z., & Zhang, W. (2021, January). Community-centric graph convolutional network for unsupervised community detection. In *Proceedings of the Twenty-Ninth International Conference on International Joint Conferences on Artificial Intelligence* (pp. 3515-3521).
- Ivannikova, E., Park, H., Hämäläinen, T., & Lee, K. (2018). Revealing community structures by ensemble clustering using group diffusion. *Information Fusion*, 42, 24-36.
- Jia, Y., Zhang, Q., Zhang, W., & ang, X. (2019, May). Communitygan: Community detection with generative adversarial nets. In *The World Wide Web Conference* (pp. 784-794).
- Jin, D., Gabrys, B., & Dang, J. (2015). Combined node and link partitions method for finding overlapping communities in complex networks. *Scientific reports*, 5 (1), 1-8.
- Jin, D., Ge, M., Li, Z., Lu, W., He, D., & Fogelman-Soulie, F. (2017, November). Using deep learning for community discovery in social networks. In *2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI)* (pp. 160-167). IEEE.
- Jin, D., Liu, Z., Li, W., He, D., & Zhang, W. (2019, July). Graph convolutional networks meet markov random fields: Semi-supervised community detection in attribute networks. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 33, No. 01, pp. 152-159).
- Kanawati, R. (2014, August). YASCA: an ensemble-based approach for community detection in complex networks. In *International Computing and Combinatorics Conference* (pp. 657-666). Springer, Cham.
- Li, Y., Han, Q., & Liu, J. (2019, November). Community Detection based on Autoencoder Reconstruction Similarity Matrix. In *Journal of Physics: Conference Series* (Vol. 1345, No. 3, p. 032055). IOP Publishing.
- Liu, C., Liu, J., & Jiang, Z. (2014). A multiobjective evolutionary algorithm based on similarity for community detection from signed social networks. *IEEE transactions on cybernetics*, 44 (12), 2274-2287.
- Liu, F., Xue, S., Wu, J., Zhou, C., Hu, W., Paris, C.,... & Yu, P. S. (2020). Deep learning for community detection: progress, challenges and opportunities. *arXiv preprint arXiv:2005.08225*.

- Liu, R., Wang, H., & Yu, X. (2018). Shared-nearest-neighbor-based clustering by fast search and find of density peaks. *Information Sciences*, 450, 200-226.
- Liu, J. (2010, October). Comparative analysis for k-means algorithms in network community detection. In *International Symposium on Intelligence Computation and Applications* (pp. 158-169). Springer, Berlin, Heidelberg.
- Lusseau, D., & Newman, M. E. (2004). Identifying the role that animals play in their social networks. *Proceedings of the Royal Society of London. Series B: Biological Sciences*, 271 (suppl_6), S477-S481.
- Mahmood, A., & Small, M. (2015). Subspace based network community detection using sparse linear coding. *IEEE Transactions on Knowledge and Data Engineering*, 28 (3), 801-812.
- Newman, M. E. (2004). Fast algorithm for detecting community structure in networks. *Physical review E*, 69 (6), 066133.
- Newman, M. E. (2006). Modularity and community structure in networks. *Proceedings of the national academy of sciences*, 103(23), 8577-8582.
- Salehi, S. M., & Pouyan, A. A. (2020). Detecting overlapping communities in social networks using deep learning. *International Journal of Engineering*, 33 (3), 366-376.
- Shchur, O., & Günnemann, S. (2019). Overlapping community detection with graph neural networks. *arXiv preprint arXiv:1909.12201*.
- Souravlas, S., Anastasiadou, S., & Katsavounis, S. (2021). A Survey on the Recent Advances of Deep Community Detection. *Applied Sciences*, 11 (16), 7179.
- Sperlí, G. (2019, April). A deep learning based community detection approach. In *Proceedings of the 34th ACM/SIGAPP Symposium on Applied Computing* (pp. 1107-1110).
- Su, X., Xue, S., Liu, F., Wu, J., Yang, J., Zhou, C.,... & Yu, P. S. (2021). A Comprehensive Survey on Community Detection with Deep Learning. *arXiv preprint arXiv:2105.12584*.
- Tian, F., Gao, B., Cui, Q., Chen, E., & Liu, T. Y. (2014, June). Learning deep representations for graph clustering. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 28, No. 1).
- Wang, F., Zhang, B., Chai, S., & Xia, Y. (2018). Community detection in complex networks using deep auto-encoded extreme learning machine. *Modern Physics Letters B*, 32 (16), 1850180.
- Wang, C., Pan, S., Hu, R., Long, G., Jiang, J., & Zhang, C. (2019). Attributed graph clustering: A deep attentional embedding approach. *arXiv preprint arXiv:1906.06532*.

- Wang, F., Zhang, B., & Chai, S. (2019). Deep auto-encoded clustering algorithm for community detection in complex networks. *Chinese Journal of Electronics*, 28 (3), 489-496.
- Wu, L., Zhang, Q., Chen, C. H., Guo, K., & Wang, D. (2020). Deep learning techniques for community detection in social networks. *IEEE Access*, 8, 96016-96026.
- Xie, Y., Gong, M., Wang, S., & Yu, B. (2018). Community discovery in networks with deep sparse filtering. *Pattern Recognition*, 81, 50-59.
- Xie, Y., Wang, X., Jiang, D., & Xu, R. (2019). High-performance community detection in social networks using a deep transitive autoencoder. *Information Sciences*, 493, 75-90.
- Xin, X., Wang, C., Ying, X., & Wang, B. (2017). Deep community detection in topologically incomplete networks. *Physica A: Statistical Mechanics and its Applications*, 469, 342-352.
- Xu, R., Che, Y., Wang, X., Hu, J., & Xie, Y. (2020). Stacked autoencoder-based community detection method via an ensemble clustering framework. *Information sciences*, 526, 151-165.
- Yang, J., McAuley, J., & Leskovec, J. (2013, December). Community detection in networks with node attributes. In *2013 IEEE 13th international conference on data mining* (pp. 1151-1156). IEEE.
- Yang, L., Cao, X., He, D., Wang, C., Wang, X., & Zhang, W. (2016, July). Modularity Based Community Detection with Deep Learning. In *IJCAI* (Vol. 16, pp. 2252-2258).
- Yang, T., Jin, R., Chi, Y., & Zhu, S. (2009, June). Combining link and content for community detection: a discriminative approach. In *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 927-936).
- Ye, F., Chen, C., & Zheng, Z. (2018, October). Deep autoencoder-like nonnegative matrix factorization for community detection. In *Proceedings of the 27th ACM international conference on information and knowledge management* (pp. 1393-1402).
- Zachary, W. W. (1977). An information flow model for conflict and fission in small groups. *Journal of anthropological research*, 33 (4), 452-473.
- Zhang, Y., Xiong, Y., Ye, Y., Liu, T., Wang, W., Zhu, Y., & Yu, P. S. (2020, August). SEAL: Learning Heuristics for Community Detection with Generative Adversarial Networks. In *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (pp. 1103-1113).

References [In Persian]

- Ghasemipoor, M., Seifi, A., & Alizadeh, H. (2019). Recognition of communities in social networks. *The second national industrial and*

systems engineering conference, Isfahan, <https://civilica.com/doc/251290>

- Hosseinian, A. H., Teimourpour, B., & Jamali Hondori, B. (2019). A Hybrid Algorithm for Detecting Communities of Social Networks based on the Modularity Density Criterion. *Business Intelligence Management Studies*, 8(29), 61-86. doi: 10.22054/ims.2019.10376
- Kosari Langari, R., Sardar, S., Amin Mousavi, S. A., & Radfar, R. (2019). A Model to Publish Online Social Networks Data with Privacy Preserving. *Business Intelligence Management Studies*, 8(29), 87-112. doi: 10.22054/ims.2019.10377
- Rohan, S., Amirian, S., & Mohammadian, A. (2017). Identification and Ranking of Social Mining Applications in E-Commerce. *Business Intelligence Management Studies*, 6(21), 1-32. doi: 10.22054/ims.2018.8510
- Roshani, S., Rezaeenik, N., & Shojaei, S. M. H. (2013). A comparative study of Usability and Sociability Of public and specialized social networking websites. *Business Intelligence Management Studies*, 2(5), 97-132.
- Shoar, M., & Salarneshad, A. A. (2018). A New Method to Cluster HTML Documents Using Mixed Algorithms. *Business Intelligence Management Studies*, 6(24), 37-62. doi: 10.22054/ims.2018.8891

استناد به این مقاله: حسینی، منیره، گلوی، الناز. (۱۴۰۲). تشخیص اجتماع در شبکه‌های اجتماعی با رویکرد یادگیری عمیق، مطالعات مدیریت کسب و کار هوشمند، ۱۱(۴۴)، ۸۳-۱۱۲.

DOI: 10.22054/ims.2023.66048.2125



Journal of Business Intelligence Management Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License..