

Link Prediction on Social Networks Based on Deep Learning

¹ Mohammad Mehdi Keikha, ²Maseud Rahgozar

¹ PhD Candidate, University of Tehran, Tehran, Iran
Mehdi.keikha@ut.ac.ir

¹ Faculty member, University of Sistan and Baluchestan, Zahedan, Iran

² Associate Professor, University of Tehran, Tehran, Iran
rahgozar@ut.ac.ir

Abstract

Link prediction on social networks is one of the issues that has attracted many researchers in recent years. In this problem, missing and future links are predicted by using existing links in the. One of the newest approaches to this problem is the use of deep learning to extract the vector of the features of each node and then find missing and future links. This paper presents a method for learning the vector representation of network nodes based on the information of the nodes adjacent to each node in the social network and the various links present on the network. The results show that the proposed method provides good results for link prediction in comparison with other methods.

Keywords: Link prediction, Deep Learning, feature vector of node, network communities, social networks.

پیش‌بینی روابط در شبکه‌های اجتماعی مبتنی بر یادگیری عمیق

محمد مهدی کیخا^۱، مسعود رهگذر^۲

^۱ دانشجوی دکترا، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران، تهران، ایران

عضو هیئت علمی، دانشگاه سیستان و بلوچستان، زاهدان، ایران

mehdi.keikha@ut.ac.ir

^۲ دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران، تهران، ایران

rahgozar@ut.ac.ir

چکیده

پیش‌بینی ارتباطات در شبکه‌های اجتماعی، یکی از مسائلی است که در سال‌های اخیر مورد توجه بسیاری از محققین قرار گرفته است. در این مساله سعی بر اینست که به کمک ارتباطات موجود در شبکه، ارتباطات از بین رفته و یا ارتباطات آتی در شبکه شناسایی شوند. یکی از جدیدترین رویکردهای این مسئله، استفاده از یادگیری عمیق جهت استخراج بردار ویژگی‌های هر گره و یافتن ارتباطات ناشناخته برای آنهاست. در این مقاله روشی برای یادگیری بردار نمایش گره‌های شبکه بر اساس اطلاعات گره‌های مجاور هر گره در شبکه اجتماعی و جوامع مختلف موجود در شبکه ارائه شده است. نتایج بدست آمده حاکی از این است که روش ارائه شده در مقایسه با سایر روش‌ها، نتایج خوبی برای پیش‌بینی ارتباطات ارائه نموده است.

کلمات کلیدی

پیش‌بینی ارتباطات، یادگیری عمیق، بردار نمایش گره، جوامع گراف، شبکه اجتماعی.

متنوع مانند شبکه‌های بیولوژیکی [۲]، پیشنهاد دوستی [۴، ۳]، پیشنهاد دهی کالاها [۵، ۶] و غیره استفاده شده است.

۱- مقدمه

پیش‌بینی ارتباطات یکی از مسائل بسیار مهم و قدیمی در حوزه شبکه‌های اجتماعی است که با استخراج یک مدل از بر اساس اطلاعات گوناگون افراد در شبکه اجتماعی، سعی در شناسایی ارتباطات از بین رفته و ارتباطات آتی دارد.

در سال‌های اخیر، روش‌های بسیاری برای پیش‌بینی ارتباطات در یک شبکه اجتماعی پیشنهاد شده اند وانگ و همکاران در [۷]، روش‌های پیش‌بینی ارتباطات را به ۳ دسته تقسیم نموده‌اند که عبارتند از: روش‌های مبتنی بر گره‌های شبکه، روش‌های مبتنی بر ساختار شبکه و روش‌های مبتنی بر تئوری‌های اجتماعی.

روش‌های مبتنی بر گره فرض می‌کنند که بین دو گره مشابه، احتمال وجود ارتباط بیشتر از سایر گره‌ها می‌باشد. این روش‌ها از اطلاعات مختلفی مانند پروفایل، محتويات تولید شده توسط هر کاربر و غیره استفاده می‌کنند تا

شبکه‌های اجتماعی آنلاین مانند فیس بوک، توییتر، تلگرام و غیره خدمات مختلفی را برای تبادل اطلاعات ارائه می‌دهند. با توجه به ماهیت بسیار پویای شبکه‌های اجتماعی، تجزیه و تحلیل آنها در سال‌های اخیر توجه بیشتری را به خود جلب کرده است. در سال‌های اخیر بررسی‌های بسیار مختلفی بر روی شبکه‌های اجتماعی به منظور استخراج داش ارزشمند موجود در آنها انجام شده است. یکی از مهمترین مسائل در حوزه شبکه اجتماعی پیش‌بینی ارتباطات است که تلاش می‌کند ارتباطات پنهانی موجود در شبکه اجتماعی را بر اساس اطلاعات مختلف موجود از جمله ارتباطات و متون منتشر شده توسط هر گره در شبکه اجتماعی پیدا کند [۱]. حل مساله پیش‌بینی ارتباطات کمک شایانی جهت درک نحوه تکامل شبکه و کشف ارتباطات نهفته در شبکه فعلی می‌نماید. پیش‌بینی پیوند در برنامه‌های

نتایج آزمایش‌ها صورت گرفته و تحلیل آن‌ها در بخش چهارم ارائه شده است. در نهایت در بخش ۵ نیز به نتیجه گیری و ارائه مسیرهای تحقیقاتی مرتبط با این مساله می‌پردازیم.

۲- تحقیقات پیشین

همانطور که در بخش قبل به آن اشاره شد، دسته‌ای از روش‌های پیش‌بینی ارتباطات، با استفاده از یادگیری عمیق ابتدا یک بردار نمایش برای هر گره از گره‌ها ارائه می‌نمایند و سپس با استفاده از یک کلاس بند‌ساده، ارتباطات جدید را پیش‌بینی می‌نمایند. در ادامه چندین روش مختلف برای یادگیری بردار نمایش گره‌ها در شبکه را مورخواهیم نمود که نتایج خوبی در پیش‌بینی ارتباطات ارائه نموده‌اند.

الگوریتم Deepwalk یکی از اولین تحقیقات صورت گرفته در زمینه نمایش گراف توسط شبکه‌های عصبی عمیق می‌باشد [18]. در این روش از قدم زنی‌های تصادفی متوالی به عنوان دانش زمینه‌ای برای یافتن نمایش یک گره استفاده می‌گردد. در این روش به دلیل آنکه از قدم زنی‌های تصادفی در گراف استفاده می‌گردد و اطلاعات جوامع گراف را پوشش داده نمی‌شود، نمی‌تواند ساختار کلی گراف را منعکس نماید و در نتیجه یک نمایش کامل برای تمامی گره‌های گراف را ارائه نخواهد شد. از جمله یادگیری این روش می‌توان به عدم کارایی آن برای گراف‌های خلوت اشاره نمود. در [19] از همسایه‌های مستقیم و درجه دوم (همسایه همسایه) گره‌های گراف برای نمایش گره‌های آنها استفاده می‌شود. روش ارائه شده در این مقاله اگرچه توانسته است خاصیت غیر خطی بودن و خلوت بودن گراف‌های واقعی را در نظر بگیرد اما ارتباط هر گره را فقط محدود به همسایه‌های نزدیک به آن دو نموده است حال آنکه دو گره می‌توانند عضو یک جامعه باشند اما در گراف فاصله بیشتر از ۲ با یکدیگر داشته باشند. در واقع این مقاله، هر دو گرهی که با یکدیگر ارتباط مستقیم داشته باشند یا چندین همسایه مشترک داشته باشند را به عنوان دو گره مشابه از نظر ساختار در نظر می‌گیرد و تنها از این اطلاعات جهت ایجاد بردار نمایش هر گره استفاده می‌نماید حال آنکه ممکن است دو گره در قسمت‌های مختلف گراف حضور داشته باشند اما از لحاظ نقش ساختاری و یا هموفیلی (جوامع) مشابه یکدیگر باشند. روش Node2vec که به تازگی توسط لسکوک [20] ارائه شده است از قدم زنی‌های تصادفی استفاده نموده است. این روش نیز اگرچه مقیاس پذیری بالایی دارد و از دو استراتژی جستجوی DFS و BFS برای قدم زنی‌های تصادفی استفاده می‌نماید، اما نمی‌تواند تمامی اطلاعات ساختاری محلی و کلی گراف را حفظ نماید زیرا فقط از روابط رتبه اول، و دوم استفاده می‌نماید و از اطلاعات جوامع گره‌ها استفاده نمی‌کند. به همین دلیل برای نمایش گره‌ها، اطلاعات زیادی در رابطه با ساختار کلی گراف را در نظر نمی‌گیرد، همچنین این روش نیز مانند Deepwalk برای گراف‌های خلوت کارایی بالایی ندارد. اخیرا Wang و همکاران در [21] از روش‌های فاکتور گیری ماتریسی جهت یادگیری نمایش گره‌ها استفاده نموده‌اند. آنها دوتابع مختلف جهت استخراج اطلاعات جوامع و همسایه‌های تعریف می‌نمایند که این دو تابع به طور مستقل از یکدیگر بردار نمایش یک گره را می‌سازند. از آنجایی که دو تابع به طور مستقل از یکدیگر عمل می‌کنند و عملیات روی ماتریس‌ها در فاکتور گیری ماتریسی بسیار هزینه بر است، این روش مقیاس پذیری بالایی نداشته و برای گراف‌های بزرگ اصلاً کارایی ندارد.

شباهت میان دو گره را محاسبه نمایند [10, 9, 8]. در این روش‌ها، پس از محاسبه شباهت بین جفت گره‌های گوناگون در شبکه، بالاترین جفت‌های مشابه، به عنوان پیوند‌های از بین رفته یا آینده شناخته می‌شوند.

رویکردهای مبتنی بر ساختار از اطلاعات ساختاری شبکه برای اندازه گیری شباهت گره‌ها استفاده می‌کنند. برخی از روش‌های مبتنی بر ساختار، تنها همسایه‌های مشترک دو گره را به عنوان میزان شباهت [12, 11, 1] در نظر می‌گیرند. روش‌های مبتنی بر مسیر که تعداد مسیر بین دو گره را شمارش می‌کنند، از جمله یادگیری روش‌های مبتنی بر ساختار هستند [13]. پیچیدگی زمان روش‌های مبتنی بر شمارش تعداد مسیرها بیشتر از روش‌های مبتنی بر شمارش تعداد همسایه‌های مشترک است، زیرا آنها از اطلاعات ساختاری کلی شبکه ورودی برای اندازه گیری شباهت میان گره‌ها استفاده می‌کنند. قدم زنی‌های تصادفی یکی دیگر از روش‌های مبتنی بر ساختار است که ابتدا احتمال بازدید از همسایه‌های گره فعلی را محاسبه می‌کند. سپس، از آنها به عنوان میزان احتمال وجود ارتباط بین دو گره استفاده می‌کند [1]. دسته سوم روش‌های پیش‌بینی ارتباطات، روش‌های مبتنی بر تئوری‌های اجتماعی است که از همبستگی میان چندین گره، روابط سه گانه یا مثالی میان سه گره، توازن ساختاری مجموعه ای از گره‌ها و غیره به عنوان مبنای برای یافتن شباهت گره‌ها [14] استفاده می‌نماید.

آخرین گروه از روش‌های پیش‌بینی ارتباطات، روش‌های مبتنی بر یادگیری ماشین است که بردار ویژگی هر یک از ارتباطات موجود در شبکه را بر اساس صفات مختلف گره‌ها [15] استخراج می‌نماید.

گرچه تحقیقات بسیاری در حوزه پیش‌بینی ارتباطات انجام شده است، اما تمام روش‌های پیشنهادی برای یک شبکه خاص مناسب هستند و کارایی مناسبی در تمامی انواع شبکه‌ها از خود بروز نمی‌دهند. همچنین استخراج ویژگی‌های هر گره، فرآیند بسیار مهمی است که تاثیر مهمی در نتایج ارزیابی ها دارد. در این مقاله، ما یک رویکرد جدید برای حل مشکل پیش‌بینی ارتباطات با استفاده از تکنیک‌های یادگیری عمیق پیشنهاد می‌کنیم. زیرا روش‌های مبتنی بر یادگیری عمیق قادر به استخراج ویژگی‌های مناسب می‌باشند.

روش‌های مبتنی بر یادگیری عمیق یکی از روش‌های کاهش ابعاد و استخراج ویژگی‌ها است که در سال‌های اخیر در کاربردهای گوناگون بسیار مورد استفاده قرار گرفته است [17, 16]. این روش‌ها ابتدا گراف ارتباطات گره‌ها را به عنوان ورودی دریافت می‌نمایند و سپس با استخراج ویژگی‌های مختلف توسط یادگیری عمیق، سعی در یادگیری بردار نمایش گره‌های شبکه می‌نمایند. هنگامی که هر گره شبکه توسط یک بردار با ابعاد بسیار کمتر نمایش داده شد، از این بردارها جهت حل مساله پیش‌بینی ارتباطات استفاده می‌نماییم [18-21]. در این مقاله، با استفاده از یک روش بردار نمایش گره‌های شبکه، یک روش جدید برای حل مساله پیش‌بینی ارتباطات ارائه شده است. در روش ارائه شده هم از اطلاعات ساختار محلی یک گره مانند همسایه‌های مستقیم در شبکه و هم از اطلاعات ساختاری کلی شبکه مانند جوامع موجود در شبکه استفاده شده است. ادامه‌ای مقاله به صورت زیر سازماندهی شده است:

در بخش ۲ به مرور کارهای انجام شده در حوزه پیش‌بینی ارتباطات توسط روش‌های یادگیری بردار نمایش گره‌های شبکه خواهیم پرداخت. روش پیشنهادهای برای حل مساله پیش‌بینی ارتباطات در بخش سوم و

Algorithm 1: CARE (G, w, d, μ, l)

```

Input:
    Graph G (V, E)
    Window length w
    Representation size d
    Number of random walks per node μ
    Random walk max length l
Output:
    Matrix of node representations  $f \in \mathbb{D}^{|V|} \times d$ 
1: Com = ModularityMaximization(G)
2: sample  $f$  from  $\mathbb{D}^{|V|} \times d$ 
3: while ( $i < \mu$ )
4:   s = shuffle (V)
5:   for each  $v_i \in s$  do
6:      $\mathcal{W}_{v_i} = \text{CommunityawareRW} (G, v_i, \text{Com}, l)$ 
7:     SkipGram ( $f, \mathcal{W}_{v_i}, w$ )
8:   end for
9: end while

```

همانگونه که در الگوریتم CARE مشاهده می شود، در گام ۱ ابتدا جوامع مختلف گراف ورودی تشخیص داده می شوند. سپس در گام ۲ بردار نمایش هر گره مقدار دهی اولیه می شود. سپس برای هر گره در شبکه به تعداد μ مسیر ویژه ایجاد می گردد تا اطیانیان حاصل شود که تمامی اطلاعات ساختار محلی و ساختار کلی گراف برای هر گره حفظ خواهد شد. برای جلوگیری از واپستگی روش به ترتیب مشاهده گردهای شبکه، در گام ۴ ترتیب آنها بصورت تصادفی تغییر داده می شود. در گام ۶ به ازای هر گره یک مسیر تصادفی ایجاد می شود که این مسیر حاوی اطلاعات همسایه های و اطلاعات گره هایی است که با گره های مشاهده شده در یک جامعه قرار دارند. سپس مسیر ایجاد شده برای یک گره به الگوریتم Skip-Gram تحویل داده می شود تا به کمک این روش، بردار نمایش هر گره یادگرفته شود.

پس از آنکه ویژگی های هر گره استخراج شد، الگوریتم CARE بردار ویژگی های دو گره را توسط عملگر هadamard در هم ضرب نموده تا بردار ویژگی های هر یال از گراف مطابق رابطه (۱) بدست آید.

$$\text{Hadamard}(u, v): f(u)_i * f(v)_i \quad (1)$$

در رابطه (۱) $f(u)_i * f(v)_i$ ویژگی i ام گردهای v, u است. البته می توانیم به جای عملگر هadamard از سایر عملگرها مانند جمع یا میانگین نیز برای استخراج بردار ویژگی یالها بر اساس بردار ویژگی گره ها استفاده نمود، اما طبق آزمایش ها و ارزیابی های انجام شده در [20] عملگر هadamard بهترین نتایج را در مساله پیش بینی ارتباطات ارائه نموده است.

۴- نتایج عملی و ارزیابی

جهت ارزیابی روش پیشنهادی برای مساله ارتباطات، از چندین الگوریتم استخراج بردار نمایش گردهای شبکه استفاده شده است که این الگوریتم ها عبارتند از:

الگوریتم همسایه های مشترک (CN) [11]: این روش با شمارش تعداد همسایه های مشترک میان دو گره، احتمال ایجاد ارتباط میان دو گره را محاسبه می نماید. این روش یکی از بهترین روش های پیش بینی ارتباطات است که مبتنی بر ساختار شبکه می باشد.

همانطور که گفته شد، تحقیقات زیادی در زمینه پیش بینی ارتباطات وجود دارد اما هیچ معماری وجود ندارد که از تمام اطلاعاتی که در شبکه ارائه شده است استفاده نماید.

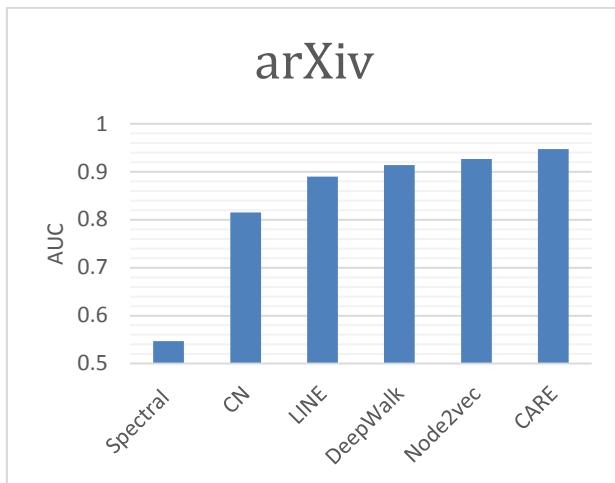
۳- روش پیشنهادی

همانگونه که در بخش قبل مشاهده نمودیم، تمامی روش های یادگیری بردار گردهای شبکه به کمک یادگیری عمیق، ابتدا تعدادی از گردهای مرتب با هر گره را توسط استراتژی های مختلف استخراج می نمایند و سپس از این گردها به عنوان داشن زمینه برای یادگیری بردار نمایش هر گره استفاده می کنند. تفاوت روش های مختلف ارائه شده، در نحوه استخراج گردهای مرتب با یک گره خاص می باشد. اکثر روش های ارائه شده فقط از همسایه های مستقیم و همسایه های درجه دوم به عنوان گردهای مرتب استفاده می نمایند. حال آنکه روش پیشنهادی ارائه شده که به اختصار CARE نامیده می شود، ابتدا برای هر گره تعدادی مسیر از گردهای مرتب با آن ایجاد می نماید. هنگام تشکیل مسیرها، از اطلاعات جوامع موجود در گراف از برخی گردها که در همسایگی گرده نمی باشند اما با گرده مورد نظر در یک جامعه قرار دارند، نیز به عنوان داشن زمینه ای برای یادگیری نمایش برداری آن گرده استفاده می شود. با توجه به اینکه اطلاعات جوامع یک گراف، حاوی ساختار کلی گراف است و اکثر روش های پیشین از این اطلاعات هیچگونه استفاده ای ننموده اند، استفاده از این اطلاعات در هنگام یادگیری بردار نمایش گردهای شبکه می تواند نتایج خوبی داشته باشد.

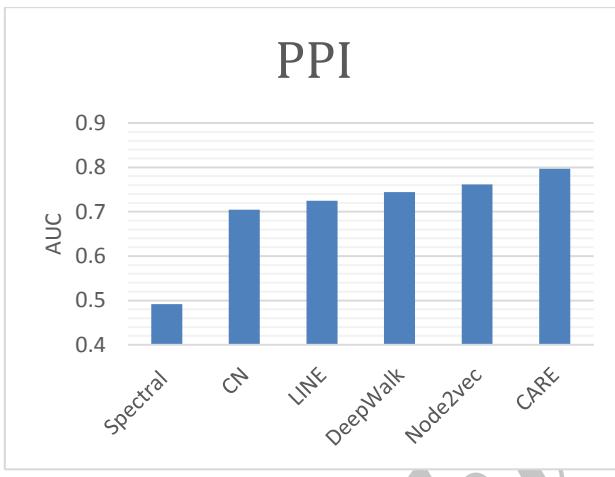
در ابتدا برای تعیین برچسب گردهای شبکه، از الگوریتم لوین برای تشخیص جوامع مختلف شبکه ورودی استفاده شده است [22].

این روش به کمک پیشینه نمودن خاصیت پیمانه ای در شبکه سعی در تشخیص جوامع آن دارد. خاصیت پیمانه ای یک معیار برای مقایسه چگالی گردهایی است که با گردهای داخل یک جامعه نسبت به گردهای خارج از آن جامعه ارتباطات بیشتری دارند. لوین برای حل این مساله بهینه سازی ابتدا تمامی گردها را به کل جوامع شبکه اختصاص می دهد و سپس در تکرارهای مختلف الگوریتم، هر گره را به جامعه جدیدی اختصاص می دهد به نحوی که در آن جامعه، مقدار پیمانه ای بودن برای آن گره حداقل شود.

پس از اینکه جوامع مختلف گراف ورودی استخراج شده باشد، به تولید مسیرهای ویژه ای می شود که علاوه بر اطلاعات همسایه های یک گرده اطلاعات گردهایی که با گرده مبدأ مسیر در یک جامعه قرار دارند را نیز شامل شود. برای تولید مسیرهای برای هر گره مشاهده شده در طی روند ایجاد مسیر، با احتمال α یکی از همسایه های مستقیم گرده مشاهده شده را انتخاب و با احتمال $1 - \alpha$ یکی از گردهایی برگزیده می شود که با گرده مشاهده شده در یک جامعه قرار گرفته باشد. به این ترتیب CARE قادر خواهد بود هم ساختار محلی یک گرده و هم ساختار کلی گراف را هنگام استخراج ویژگی هایی که گرده مد نظر قرار دهد. برای یادگیری بردار نمایش هر گره با استفاده از مسیرهای ویژه ایجاد شده از الگوریتم Skip-Gram استفاده می شود که پیش از این در پردازش زبان طبیعی از آن استفاده شده است [23]. الگوریتم ۱ مراحل انجام این روش را تشرییح می نماید:



شکل ۱: مقایسه روش های مختلف پیش بینی ارتباطات توسط arXiv



شکل ۲: مقایسه روش های مختلف پیش بینی ارتباطات توسط PPI

استخراج ویژگی های گره های شبکه می نماید و هیچ تصمیمی مبنی بر حفظ ویژگی های ساختاری محلی و کلی شبکه وجود ندارد. روش های Node2vec و DeepWalk برای استخراج بردار ویژگی هر گره، مسیرهایی به طور تصادفی تولید می کنند و هیچ اطلاعاتی در مورد جوامع گره ها در آنها وجود ندارد. اگر چه، Node2vec تلاش می کند تا با استفاده از دو پارامتر کنترل شده، اطلاعات جوامع را مورد بررسی قرار دهد، اما این پارامترها نمی توانند اطمینان حاصل کنند که اطلاعات مربوط به گره ها را در یک مسیر تصادفی گنجانده اند. در مقابل CARE، Node2vec این اطلاعات را به یک پیاده روی تصادفی سفارشی جاسازی می کند در حالیکه با احتمال α به گره هایی که در همان جامعه با آخرین گره در طول مسیر هستند پرش می کنیم.

۵- نتیجه گیری

در این مقاله روشی برای حل مساله پیش بینی ارتباطات مبتنی بر یادگیری بردار نمایش گره های شبکه ارائه شده است. روش پیشنهادی هنگام یادگیری بردار نمایش گره های شبکه هم ساختار محلی شامل همسایه های و هم ساختار کلی گراف شامل جوامع موجود در گراف را در نظر می گیرد. نتایج ارزیابی های انجام شده بر روی دو مجموعه داده استاندارد نشان از عملکرد

الگوریتم Spectral clustering [24] : این الگوریتم با استفاده از برش های مختلف گراف، سعی در شناسایی برچسب های مختلف گره می کند. برای یافتن برش های مختلف گراف، ابتدا ماتریس لاپلاسین نرمال شده گراف را محاسبه می نماید و سپس d کوچکترین مقدار بردار ویژه را به عنوان بردار نمایش هر گره انتخاب می نماید.

الگوریتم DeepWalk [18]: این روش نخستین الگوریتمی است که با استفاده از بردار نمایش گره ها که توسط یادگیری عمیق بدست می آورد برای حل مساله دسته بندی چند برچسبی استفاده می نماید. این روش در ابتدا به ازای هر گره، تعدادی قدم زنی تصادفی ایجاد می کند و از این مسیرهای تصادفی به عنوان اطلاعات زمینه برای یادگیری بردار نمایش گره ها در فضای d بعدی استفاده می کند. در نهایت با استفاده از یک دسته بند ساده اقدام به شناسایی برچسب های یک گره می کند.

الگوریتم LINE [19]: این روش دوتابع جداگانه برای جمع آوری اطلاعات همسایه های مستقیم و همسایه های درجه دوم گره استفاده می کند و از اطلاعات جمع آوری شده توسط این دوتابع جهت یادگیری بردار نمایش گره ها استفاده می کند.

الگوریتم Node2vec [20]: این روش نیز مانند DeepWalk از قدم زنی های تصادفی برای جمع آوری اطلاعات گره ها استفاده می نماید. تفاوت اصلی آن با DeepWalk در این است که این روش فقط از همسایه های مستقیم و همسایه های درجه دوم گره برای ایجاد مسیرهای تصادفی استفاده می کند.

برای ارزیابی کامل CARE از دو مجموعه داده استاندارد استفاده شده است که اطلاعات آنها در جدول زیر ارائه شده است:

جدول ۱: مشخصات مجموعه داده های مورد استفاده در آزمایش ها

نام مجموعه داده	تعداد گره ها	تعداد یالها
PPI [25]	19706	390633
arXiv ASTRO-PH [26]	18772	198110

جهت ارزیابی روش پیشنهادی از معیار AUC استفاده می نماییم که پیش از این نیز در [20] جهت ارزیابی پیش بینی ارتباطات مورد استفاده قرار گرفته است. معیار AUC بیانگر میزان دقیقی است که احتمال وجود ارتباط بین دو گره توسط روش پیشنهادی را با احتمال پیش بینی ارتباط به صورت تصادفی مقایسه می نماید و در واقع کیفیت روش پیشنهادی را در مقایسه با روش تصادفی ارزیابی می نماید.

در ادامه مقدار AUC روش های ذکر شده در مجموعه داده های مختلف در شکل های ۱ و ۲ نمایش داده شده است.

همانگونه که در شکل های ۱ و ۲ مشاهده می گردد، روش CARE در هر دو مجموعه داده در مقایسه با سایر روش های پیش بینی ارتباطات عملکرد بهتری را نشان می دهد. روش همسایه مشترک نسبت به روش Spectral clustering نتایج بهتری داشته است که دلیل آن تضمین در نظر گرفتن اطلاعات ساختاری محلی می باشد. همانگونه که اشاره شد روش CARE با استفاده از بردار ویژه ماتریس مجاورت اقدام به

- [19] Grover, A., and Leskovec, J., “Node2vec: Scalable feature learning for networks,” In Proc. of the 22nd ACM SIGKDD, pp. 1225–1234, 2016.
- [20] Wang, X., Cui, P., Wang, J., Pei, J., Zhu, W., and Yang, S., “Community preserving network embedding,” in AAAI, pp. 203–209, 2017.
- [21] Blondel, V. D., Guillaume, J., Lambiotte, R., Lefebvre, E., “Fast unfolding of communities in large networks” Journal of Statistical Mechanics: Theory and Experiment, Vol. 10, 2008.
- [22] Mikolov, T., Chen, K., Corrado, G., and Dean, J., “Efficient estimation of word representations in vector space,” In ICLR, 2013.
- [23] Breitkreutz, B. J., Stark, C., Reguly, T., Boucher, L., Breitkreutz, A., Livstone, M., Oughtred, R., Lackner, D. H., Bähler, J., and Wood, V., “The BioGRID interaction database” Nucleic acids research, Vol. 36, pp. 637–640, 2008.
- [24] Mahoney, M., Large text compression benchmark. www.mattmahoney.net/dc/textdata, 2011.
- [25] Leskovec, J., and Krevl, A., SNAP Datasets: Stanford large network dataset collection. http://snap.stanford.edu/data, June 2014.

زیرنویس

¹ Community aware random walk for network embedding

² Graph cuts

³ Eigen vectors

مطلوب روش پیشنهادی در مقایسه با سایر روش های نمایش برداری برای حل مساله پیش بینی ارتباطات است.

مراجع

- [1] Liben-Nowell, D., and Kleinberg, J. M., “The link prediction problem for social networks”, Journal of the American Society for Information Science and Technology, Vol. 58, pp. 1019-1031, 2007.
- [2] Almansoori, W., Gao, S., Jarada, T. N., and et al. “Link prediction and classification in social networks and its application in healthcare and systems biology”. Network Modeling Analysis Health Informatics Bioinformatics, Vol. 1, pp. 27-36, 2012.
- [3] Aiello, L. M., Barrat A., Schifanella, R., and et al. “Friendship prediction and homophily in social media”, ACM Transactions on the Web, Vol. 6, No. 9, 2012.
- [4] Mori, J., Kajikawa, Y., Kashima, H., and et al. “Machine learning approach for finding business partners and building reciprocal relationships”, Expert Systems with Applications, Vol. 39, pp. 10402-10407, 2012.
- [5] Akcora, C. G., Carminati, B., Ferrari, E. “Network and profile based measures for user similarities on social networks”, In Proc. of the 12th IEEE International Conference on Information Reuse and Integration, Las Vegas, USA, 2011.
- [6] Tang, J., Wu, S., Sun, J. M., and et al. “Cross-domain collaboration recommendation”, In Proc. of the 18th ACM SIGKDD International Conference on Discovery and Data Mining (KDD'12), Beijing, China, pp. 1285-1293, 2012.
- [7] Wang, P., Xu, B., Wu, Y., and Zhou, X. “Link prediction in social networks: The state-of-the-art”. Science China Information Sciences, Vol. 58, No. 1, pp. 1-38, 2015.
- [8] Anderson, A., Huttenlocher, D., Kleinberg, J., and et al. “Effects of user similarity in social media”, In Proc. of the 5th ACM International Conference on Web Search and Data Mining (WSDM'12), Seattle, USA, pp. 703-712, 2012.
- [9] Akcora, C. G., Carminati, B., and Ferrari, E. “User similarities on social networks”, Social Network Analysis and Mining, Vol. 3, pp. 475-495, 2013.
- [10] Adamic, L. A., and Adar, E. “Friend and neighbors on the web”, Social Networks, Vol. 25, pp. 211-230, 2003.
- [11] Newman, M. E. J., “Clustering and preferential attachment in growing networks”, Physical Review Letters E, Vol. 64, 2001.
- [12] Lichtenwalter, R. N., and Chawla, N. V. “Vertex collocation profiles: subgraph counting for link analysis and prediction”, In Proc. of the 21st World Wide Web Conference(WWW'12), Lyon, France, pp. 1019-1028, 2012.
- [13] Liu, H., Hu, Z., Haddadi, H., and et al. “Hidden link prediction based on node centrality and weak ties”. EPL (Europhysics Letters), Vol. 101, 2013.
- [14] Wohlfarth, T., and Ichise, R., “Semantic and event-based approach for link prediction”, In Proc. of the 7th International Conference on Practical Aspects of Knowledge Management (PAKM'08), Yokohama, Japan, pp. 50-61, 2008.
- [15] Bengio, Y., Courville, A., and Vincent, P., “Representation learning: A review and new perspectives” IEEE TPAMI, Vol. 35, No. 8, pp.1798–1828, 2013.
- [16] Yu, X., Ren, X., Sun, Y., Gu, Q., Sturt, B., Khandelwal, U., Norick, B., and Han, J., “Personalized entity recommendation: A heterogeneous information network approach,” In WSDM, pp. 283-292, 2014.
- [17] Perozzi, B., Al-Rfou, R., and Skiena, S.. “DeepWalk: Online learning of social representations,” In KDD, 2014.
- [18] Tang, J., Qu, M., Wang, M., Zhang, M., Yan, J., and Mei, Q., “LINE: Large-scale Information Network Embedding,” In WWW, 2015.