


## تعبیه‌سازی شبکه‌های ناهمگن با استفاده از شبکه‌های عصبی گراف (Heterogeneous Networks Embedding via Graph Neural Networks)

فاطمه بهاری‌فرد

پژوهشکده علوم کامپیوتر، پژوهشگاه دانش‌های بنیادی

### خلاصه طرح

با توجه به نقش بسیار مهم و حیاتی داده‌ها در زندگی امروزه، یکی از حوزه‌های اصلی پژوهش در این زمینه نمایش کارآمد داده‌ها و در نتیجه تحلیل آن‌ها است. برای نمایش اکثر مجموعه داده‌ها می‌توان از ساختار قدرتمند گراف استفاده کرده و موجودیت‌ها و روابط موجود در داده‌ها را به ترتیب با رئوس و یال‌های مابین آن‌ها نشان داد. به عنوان مثال، مجموعه داده‌های مربوط به شبکه‌های اجتماعی [۱]، شبکه‌های ترافیکی [۲]، شبکه‌های استنادی [۳] از نمونه‌هایی هستند که امکان نمایش آن‌ها با گراف‌ها وجود دارد. اگر گراف فقط یک نوع رأس و یک نوع یال داشته باشد، گراف همگن<sup>۱</sup> نامیده می‌شود. اما، در بسیاری از مجموعه داده‌های دنیای واقعی، جنبه‌های مختلف اطلاعات با هم ترکیب می‌شوند و داده‌ها تمایل دارند به‌عنوان یک گراف ناهمگن<sup>۲</sup> [۴] ارائه شوند که در این نوع گراف‌ها، رئوس و یال‌ها انواع مختلفی دارند. شبکه‌های اطلاعاتی ناهمگن<sup>۳</sup> (HIN) به دلیل داشتن اطلاعات جامع و معنانشناسی غنی در بسیاری از وظایف داده کاوی استفاده می‌شوند. مثالی از این شبکه‌ها در شکل (۱) آورده شده است که مربوط به مجموعه داده یک شبکه استنادی است که شامل سه نوع رأس (مقاله، نویسنده و محل برگزاری) و سه نوع یال (نوشتن، استناد و انتشار) می‌باشد. بر اساس هدف مطالعه، این شبکه‌ها می‌توانند به صورت جهت‌دار یا بی‌جهت و هم‌چنین وزن‌دار یا بی‌وزن نمایش داده شوند.



شکل (۱): نمونه شبکه استنادی ناهمگن

وابسته به مساله مورد پژوهش، در مطالعه برخی از مجموعه داده‌ها، علاوه بر روابط ساختاری موجود، می‌توان اطلاعات غنی کمکی مانند برجسب، صفت و ویژگی رئوس را به توپولوژی گراف اضافه کرد تا بتوان به صورت ترکیبی از مجموع اطلاعات ساختاریافته و بدون ساختار در تحلیل و انجام تسک مورد نظر استفاده نمود [۵،۶]. در واقع با تجزیه و تحلیل کارآمد شبکه‌های ناهمگن می‌توان اطلاعات پنهان موجود در آن‌ها را کشف کرده و در کاربردهای بسیاری مانند خوشه‌بندی رئوس<sup>۴</sup>، طبقه‌بندی رئوس<sup>۵</sup>، پیش‌بینی

<sup>1</sup> Homogeneous graph

<sup>2</sup> Heterogeneous graph

<sup>3</sup> Heterogeneous Information Network (HIN)

<sup>4</sup> Node clustering

<sup>5</sup> Node classification

پیوندها<sup>۶</sup> و غیره مورد استفاده قرار داد. یکی از روش‌های بررسی گراف‌ها، تعبیه سازی (جاسازی)<sup>۷</sup> نودهای گراف است. در تعبیه سازی نودهای گراف در تلاش هستیم تا برای هر نود یک بردار با طول ثابت در فضای هندسی محاسبه کنیم که به ازای نودهایی که شباهت بیشتری با هم دارند، بردارهای حاصل به هم نزدیک‌تر باشند. پس یکی از چالش‌های موجود در این حوزه، چگونگی ترکیب این منابع اطلاعاتی ساختاریافته و بدون ساختار است به گونه‌ای که مفهوم شباهت رئوس حفظ شده و در نتیجه در کاربرد مورد نظر تاثیرگذار و مفید باشد. در اکثر مطالعات قبلی، شبکه‌های ناهمگن صرفاً بر اساس ساختارهای از پیش تعریف شده مورد تحلیل قرار گرفته‌اند و بسیاری از مزایای سایر اطلاعات موجود در مجموعه داده نادیده گرفته شده است [۹-۷]. هم‌چنین برخی از مطالعات پیشین که از این اطلاعات در فرایند تعبیه سازی شبکه استفاده کرده‌اند، دانش معنایی و ارتباطات نهفته‌ای که مابین رئوس وجود دارد را مورد بررسی قرار نداده‌اند [۱۱، ۱۰، ۶، ۵].

یکی از روش‌هایی که در سال‌های اخیر مورد توجه پژوهش‌گران قرار گرفته است استفاده از یادگیری عمیق<sup>۸</sup> در حل مسائل مختلف است. پس اولین سوالی که مطرح می‌شود آن است که آیا می‌توانیم تعبیه سازی گراف‌ها را نیز از طریق یادگیری عمیق بررسی کنیم یا خیر. یکی از چالش‌هایی که برای این مساله با آن مواجه می‌شویم این است که به سادگی نمی‌توانیم ساختمان داده گراف را به عنوان ورودی به شبکه عمیق دهیم و نیاز به تغییر ساختاری شبکه خواهیم داشت. به همین منظور از شبکه‌های عصبی گرافی<sup>۹</sup> برای ورودی گراف استفاده می‌شود که بتوانیم خصوصیات گراف را به طریقی وارد شبکه کنیم. از این رو در این طرح پژوهشی به مساله تحلیل و تعبیه سازی انواع گراف‌های ناهمگن به وسیله شبکه‌های عصبی گرافی با قابلیت استفاده حداکثری از اطلاعات موجود و نهفته در شبکه پرداخته و به بررسی مسائل مختلفی مانند شناسایی جماعت‌های محلی و خوشه‌بندی گراف، شناسایی نودهای خاص، پیش‌بینی ایجاد یال جدید در آینده، تعیین لیبل برای برخی نودها، و هم‌چنین ساده سازی گراف با رویکرد ادغام نودها<sup>۱۰</sup> در این نوع شبکه‌ها خواهیم پرداخت.

## شرح طرح

یک شبکه شامل تعدادی عنصر است که به واسطه‌ی چند متصل‌کننده به یکدیگر وصل شده‌اند. در مفهوم ریاضی، شبکه یک گراف  $G = (V, E)$  است که در آن  $V$  رأس بوسیله  $E$  یال به یکدیگر متصل شده‌اند. این یال‌ها می‌توانند جهت‌دار یا بدون جهت، وزن‌دار یا بدون وزن باشند. شبکه‌ی فضایی<sup>۱۱</sup> گرافی است که در آن رأس‌ها یا یال‌ها عناصر مرتبط با اشیاء هندسی هستند. به عنوان مثال رأس‌ها در یک فضای متریک مانند فضای اقلیدسی قرار گرفته‌اند. نمونه‌هایی از این نوع شبکه، شبکه‌های حرکت و حمل و نقل<sup>۱۲</sup>، اینترنت، شبکه‌های تلفن همراه، شبکه‌های توزیع برق<sup>۱۳</sup> و شبکه‌های عصبی بیولوژیکی<sup>۱۴</sup> می‌باشند. علاوه بر این شبکه‌ها، شبکه‌های غیرهندسی مانند شبکه‌های پیچیده<sup>۱۵</sup>، شبکه‌های اجتماعی و ارتباطی<sup>۱۶</sup> امروزه مورد توجه بسیاری قرار گرفته‌اند. یک شبکه‌ی پیچیده دارای ویژگی‌های توپولوژیکی خاصی است که این ویژگی‌ها در شبکه‌های ساده مانند شبکه‌های مشبک یا شبکه‌های تصادفی وجود

<sup>6</sup> Link prediction

<sup>7</sup> Embedding

<sup>8</sup> Deep learning

<sup>9</sup> Graph neural network

<sup>10</sup> Node pooling

<sup>11</sup> Spatial network

<sup>12</sup> Transportation and mobility networks

<sup>13</sup> Power grids


<sup>14</sup> Biological neural networks

<sup>15</sup> Complex networks

<sup>16</sup> Social and contact networks

ندارد. وجود دینامیک در شبکه از این گونه ویژگی‌هاست. دو کلاس شناخته شده از شبکه‌های پیچیده، شبکه‌های بدون مقیاس<sup>۱۷</sup> و شبکه‌های جهان کوچک<sup>۱۸</sup> هستند که با ویژگی‌های ساختاری خاص مثل توزیع درجه‌ی توانی، طول مسیر کوتاه و میزان درجه خوشه‌بندی مشخص می‌شوند. با این حال، از آن جا که مطالعه در مورد شبکه‌های پیچیده از اهمیت و محبوبیت خاصی برخوردار است، بسیاری از جنبه‌های دیگر ساختارهای شبکه نیز مورد توجه قرار گرفته است.

شبکه‌های ناهمگن نیز به عنوان یک نوع از شبکه‌های پیچیده است. تجزیه و تحلیل شبکه‌ی ناهمگن به منظور شناسایی الگوهای محلی و سراسری، انجام می‌گیرد. داده‌های امروزه بسیار پیچیده و با روابط متعددی هستند. این داده‌ها مقادیر متفاوتی دارند که هر کدام از آن‌ها نیز می‌تواند از انواع مختلفی باشند. به این منظور برای مدل کردن و نمایش و استفاده از این داده‌ها باید به سراغ گراف‌های ناهمگن برویم. در این گراف‌ها، هر نود می‌تواند متفاوت از بقیه باشد و به همین علت یال‌های گراف هم دارای معنا و در نتیجه نوع متفاوتی خواهند بود. با توجه به این موضوع روش‌هایی که روی گراف‌های همگن کار می‌کنند در مواجهه با این گراف‌ها دچار چالش می‌شوند. نگاهی که در گراف‌های همگن وجود دارد زمانی که بخواهد روی گراف‌های ناهمگن مورد استفاده قرار گیرد از دو جنبه قابل بررسی است، یکی آن که آن رویکرد نمی‌تواند از همه‌ی دانشی که در گراف‌های ناهمگن وجود دارد استفاده کند و دیگری آنکه اساساً آن رویکرد نمی‌تواند تنوع بین نودها و یال‌ها را درک کند. الگوریتم‌هایی که در گراف‌های ناهمگن وجود دارد تلاش می‌کنند تا تنوع بین نودها و یال‌ها را درک کنند و به طرق مختلف از دانشی که در سرتاسر گراف پراکنده شده است استفاده کنند. در این حوزه یکی از مسائلی که وجود دارد بحث تعبیه سازی نودهای گراف است به طوری که در این مساله در تلاش هستیم تا برای هر نود برداری  $d$  بعدی محاسبه کنیم که بتواند به بهترین نحو ممکن شباهت و تمایز بین نودهای مختلف را نمایش دهد. در شکل زیر نمونه‌ای از تعبیه سازی گراف مربوط به یک شبکه اجتماعی به بردارهای دو بعدی نشان داده شده است که فاصله بین نقاط در فضای دو بعدی نشانگر میزان شباهت نودها در گراف هستند.



شکل (۲): تعبیه سازی گراف

برای جاسازی گراف‌ها رویکردهای متفاوتی وجود دارد که به طور کلی می‌توان این روش‌ها را به دو دسته کم عمق و عمیق تقسیم کرد. در ادامه ابتدا توضیحی در مورد روش‌های موجود برای جاسازی گراف همگن ارائه می‌شود و سپس تعمیم‌یافته این روش‌ها برای گراف‌های ناهمگن بیان خواهد شد.

<sup>17</sup> Scale-free networks

<sup>18</sup> Small-world networks

## تعبیه سازی گراف همگن


جاسازی (تعبیه سازی) گراف چارچوبی برای نمایش یک گراف در فضای با بعد پایین است. برخی از روش‌های سنتی موفق جاسازی مانند node2vec [۱۲] و DeepWalk [۱۳] در گذشته در حوزه پردازش زبان طبیعی نیز مورد توجه قرار گرفته‌اند. در روش DeepWalk از قدم‌زنی تصادفی کوتاه و skip-gram برای جاسازی رئوس استفاده می‌شود. در این الگوریتم ابتدا مبتنی بر گراف موجود دنباله‌ای از نودها پیمایش خواهند شد. در ادامه مبتنی بر مجموعه پیمایش‌هایی که انجام شده است شبکه skip-gram آموزش می‌بیند. از آنجایی که این الگوریتم خواستگاهی از حوزه پردازش زبان طبیعی دارد می‌توان خروجی پیمایش نودها را به مثابه کلماتی از جملات دانست که شبکه skip-gram در تلاش است تا تعبیه سازی از این کلمات (در اینجا نودهای گراف) ارائه دهد. همان گونه که در پردازش زبان طبیعی تعبیه سازی کلمات زمانی خوب است که کلمات با معنی مشابه فاصله کمتری نسبت به کلمات با معانی مختلف دارند، در این جا هم نودهایی که در ساختار گراف مشابه یکدیگر هستند تعبیه سازی خواهند داشت که در فضای d بعدی فاصله‌ای نزدیک‌تر به هم را داشته باشند. الگوریتم node2vec در تلاش است تا به گونه‌ای دقت الگوریتم قبلی را بهبود دهد. در این الگوریتم به دنبال حفظ همسایگی‌های گره‌های موجود در گراف هستیم. در این الگوریتم معیارهایی برای قدم زنی تصادفی ارائه شده است تا اولاً هم امکان برگشت از نودهایی که از آن‌ها عبور کرده‌ایم وجود داشته باشد و هم بتوانیم این احتمال را تنظیم کنیم. در ادامه‌ی پژوهش‌هایی که در این حوزه انجام شده است همین تفکر تعمیم داده شد.

در سالیان اخیر یادگیری عمیق جایگاهی ویژه و ممتازی در حل مسائل مختلف داشته است. اولین سوالی که مطرح می‌شود آنست که آیا می‌توانیم همین مساله‌ای که با الگوریتم‌های DeepWalk و node2vec حل شد را با یادگیری عمیق حل کنیم؟ احتمالاً این ایده می‌تواند مسائل را با دقت بیشتری حل کند. اولین چالش در این حوزه آنست که به سادگی نمی‌توانیم ساختمان داده گراف را به عنوان ورودی به شبکه عمیق بدهیم. یک شبکه عمیق پیچشی (کانوولوشنی)<sup>۱۹</sup> زمانی که یک تصویر را در ورودی می‌گیرد به دلیل ساختار منظم پیکسل‌های تصویر و چیدمان دقیق همسایگی، می‌توانیم ورودی شبکه را به سادگی تنظیم کنیم، اما زمانی که با ساختمان داده گراف مواجه باشیم این شرایط وجود ندارد. در این حوزه اولین راهکار آن بود که به ازای هر نودی که دارای برداری از ویژگی‌هاست، فرآیند کانوولوشن را این گونه تعریف کنیم که عملیات ریاضی روی بردارهای همسایگی یک نود می‌تواند بردار مخفی لایه بعدی را بسازد. این عملیات به ازای همه‌ی نودها انجام می‌شود و در ادامه در لایه بعدی از همین بردارهای مخفی محاسبه شده استفاده خواهد شد تا لایه مخفی بعدی محاسبه شوند. برای جمع‌آوری اطلاعات مربوط به هر نود هر کدام از گره‌های گراف، مقدار بردارهای گره‌های همسایه را به شکل پیام‌هایی دریافت می‌کند و پس از دریافت این بردارها، باید آن‌ها را به کمک روشی با همدیگر و سپس با بردار مقدار خود گره ترکیب کند. پس از این ترکیب به یک بردار نهایی می‌رسیم که همه بردارهای گره‌های همسایه و همچنین خود گره در آن دخیل است. به این مکانیزم جمع‌آوری اطلاعات از گره‌های همسایه مکانیزم انتقال پیام<sup>۲۰</sup> گفته می‌شود. در این مسیر می‌توانیم برای نودهای همسایه یا یال‌هایی که بین نودها وجود دارد وزنی را در نظر بگیریم. زمانی که این مقدار وزن به صورت ثابت به ازای مساله در نظر گرفته شده باشد، الگوریتم GCN<sup>۲۱</sup> و زمانی که بخواهد مقدار این وزن‌هایی که به یال‌ها انتساب داده می‌شود توسط خود الگوریتم و در فرآیند آموزش یاد گرفته شود در اصطلاح مکانیزم توجه<sup>۲۱</sup> گفته می‌شود. در تصویر زیر مکانیزم محاسبه لایه‌های پنهان در یک گراف آمده است.

<sup>19</sup> Graph Convolutional Networks (GCN)

<sup>20</sup> Message passing mechanism


<sup>21</sup> Attention mechanism



شکل (۳): محاسبه لایه‌های پنهان شبکه

## تعبیه سازی گراف ناهمگن

بسیاری از روش‌های ارائه‌شده برای گراف‌های ناهمگن مبتنی بر یادگیری نمایش گراف<sup>۲۲</sup> هستند که به چند نمونه از آن‌ها اشاره می‌کنیم. فرامسیرها<sup>۲۳</sup> یک مفهوم تعریف شده در اکثر روش‌های جاسازی گراف ناهمگن است که در روش‌هایی مانند metapath2vec [۷] و HIN2vec [۸] از این مفهوم استفاده شده است. فرامسیر الگویی است که از دنباله‌ای از انواع رئوس تشکیل شده است که رابطه ترکیبی بین انواع مختلف رئوس در شبکه ناهمگن با این الگو نشان داده می‌شود. به طور مثال اگر در شبکه استنادی شکل (۱) نوع رئوس مقالات و نویسندگان مقالات را با P و A نمایش دهیم دنباله (APA) یک فرامسیر خواهد بود. روش metapath2vec به دنبال بیشینه کردن احتمال حفظ ساختار و معنا در یک گراف ناهمگن است. در این روش ابتدا به کمک فرامسیرها و قدم زنی تصادفی روی گراف، نمونه‌هایی از همسایگی‌های رئوس ساخته شده و سپس از skip-gram برای جاسازی رئوس استفاده می‌شود. این الگوریتم به دلیل استفاده از مکانیزم فرامسیر توانسته است وجود انواع مختلف نود و هم‌چنین یال‌های مختلف را درک کند. الگوریتم دیگری بنام HAN نیز از فرامسیر استفاده کرده است. در این الگوریتم می‌توانیم فرامسیرهایی را برای این گراف در نظر بگیریم و مبتنی بر همین فرامسیر الگوریتم HAN در تلاش است تا در دو طبقه از مکانیزم توجه استفاده کند. در طبقه اول بین نودهای مختلف مکانیزم توجه اعمال شده است و در طبقه دوم بین خروجی نودهای طبقه قبل و مبتنی بر فرامسیری که از آن استفاده شده است از توجه بهره گرفته شده است (شکل ۴). این الگوریتم نشان داد که می‌تواند به علت اعمال مکانیزم توجه، وابستگی به انتخاب مناسب متاپث را اندکی کاهش دهد و برای تسک‌های مختلف دقت بالاتری را فراهم کند.



شکل (۴): مکانیزم توجه در الگوریتم HAN

<sup>22</sup> Graph representation learning


<sup>23</sup> Metapath

در الگوریتم HetSANN تلاش شده است تا تمرکز روی انتخاب مناسب یال‌ها باشد. یکی از چالش‌هایی که در گراف‌های ناهمگن وجود دارد آنست که به شدت وابسته به انتخاب صحیح فرامسیر هستند. در این الگوریتم به جای آن که از فرامسیر بهره گرفته شده باشد تلاش شده است گراف به صورت لایه‌ای و مبتنی بر یال پیمایش شود. اطلاعات دریافت شده به یک شبکه عصبی ارسال شده و در نهایت وزن‌هایی که در خروجی محاسبه می‌شوند بیانگر تعبیه سازی نودهای گراف هستند.

روش‌های فوق قابلیت استفاده از ویژگی‌های رئوس را ندارند، اما اخیراً روش‌های نیمه-نظارتی<sup>۲۴</sup> مانند MAGNN [۱۰] و MEGNN [۱۴] که مبتنی بر یادگیری عمیق گرافی هستند برای استفاده از ویژگی رئوس پیشنهاد شده‌اند. در الگوریتم HAN چند نکته منفی وجود داشت که الگوریتم MAGNN در تلاش است آنها را آدرس دهی کند. در HAN عمل‌های میانی فرامسیر تاثیر بسیار کمی دارند و همچنین رویکرد الگوریتم به استفاده از داده‌های محلی است. در MAGNN ویژگی‌های رئوس از اطلاعات معنایی تولید شده و نتایج شناسایی تشکل با در نظر گرفتن هم‌زمان این اطلاعات و توپولوژی شبکه بهبود می‌یابد. اخیراً، یک روش جاسازی برای شبکه‌های ناهمگن پیچیده نیز پیشنهاد شده است [۱۱]، که با در نظر گرفتن مفهوم گرافلت برای شبکه‌های ناهمگن، خوشه‌بندی طیفی مرتبه بالاتر را تعمیم می‌دهد. با این حال، بسیاری از روش‌های مورد استفاده برای مطالعه خوشه‌بندی در گراف‌های ناهمگن، نیمه-نظارت شده بوده یا فقط شباهت ساختاری را ارزیابی می‌کنند. به همین دلیل، هدف این مقاله ارائه یک روش بدون ناظر برای خوشه‌بندی HINها است که در آن اطلاعات توپولوژیکی، اطلاعات متنی و ویژگی‌های موجود در مجموعه داده هم‌زمان در نظر گرفته شود تا شباهت‌یابی دقیق‌تری انجام گیرد.

## شبکه‌های چند لایه و چندگانه

یک شبکه چند لایه<sup>۲۵</sup> شبکه‌ای است که در چندین لایه قابل تفکیک باشد. هر لایه نشان‌دهنده یک حالت عملیاتی خاص، دایره اجتماعی یا نمونه زمانی است. اعتقاد بر این است که این الگوی جدید در علم شبکه، گام مهمی به سوی درک بهتر و کامل‌تر سیستم‌های مدرن سایبری، اجتماعی و فیزیکی است. یکی از بارزترین موارد کاربرد شبکه‌های چند لایه را می‌توان بررسی گسترش اپیدمی دانست. در این سناریو با فرض مشترک بودن جمعیت میزبان، می‌توان به صورت لایه به لایه گسترش بیماری را شبیه سازی و همچنین امکان تعامل و یا تقابل چند بیماری با هم را بررسی نمود. با این سناریو می‌توان بهترین پیوندهایی که سبب انتشار بیماری می‌شوند را شناسایی و در جهت قطع آن اقدام کرد. نمونه‌ای از یک شبکه‌ی چندلایه در شکل ۵ دیده می‌شود.



شکل (۵): نمونه‌هایی از شبکه‌های چندلایه


شبکه چندگانه<sup>۲۶</sup> نوعی از شبکه‌های چند لایه است که بین لایه‌های آن یالی وجود ندارد. شبکه‌های چندگانه به معنی بررسی چندین شبکه با توپولوژی متفاوت است. امروزه بسیاری از افراد در بیش از یک شبکه اجتماعی فعالیت دارند. به عنوان مثال مجموعه شبکه‌های ارتباطی فیسبوک، توئیتر، لینکدین، اینستاگرام را می‌توان از این دسته شبکه‌ها در نظر گرفت. در این چند شبکه، مجموعه

<sup>24</sup> Semi-Supervised

<sup>25</sup> Multi-layer networks

<sup>26</sup> Multiplex networks

نودها، کاربران موجود در این شبکه‌ها می‌باشند. توپولوژی این شبکه متفاوت است و هر کدام دارای اطلاعاتی هستند که در سایرین وجود ندارد. با تحلیل شبکه‌ها به صورت چندگانه اولاً امکان استفاده از اطلاعات موجود در سایر شبکه‌ها وجود دارد و ثانیاً تاثیر دیتای نویزی احتمالی به شدت کاهش می‌یابد. نوع دیگری از این شبکه‌های چندگانه را نیز با حضور چند نوع مختلف از یال می‌توان در نظر گرفت، مثلاً در گرافی که نودهای آن اعضای توییتر هستند، یال نوع فالوور-فالوینگ گراف با یکدیگر یک نوع یال و یال ریتوییت یا لایک انواع دوم و سوم هستند. اگر شبکه‌ها همگی دارای مجموعه‌ی نودهای هم نوعی باشند به آن مولتی-پلکس گویند. مانند شبکه‌ی ارتباطی بین تعدادی از افراد در دانشگاه که در این شبکه‌ی چند لایه، سه نوع ارتباط، همکاری، با یکدیگر غذا خوردن و دوست مجازی بودن در شبکه‌ی فیسبوک را در نظر گرفت (شکل ۶).



شکل ۲: نمونه‌ای از شبکه‌ی مولتی-پلکس

## شرح مسائل

از اساسی‌ترین مسائلی که در شبکه‌ها با آن مواجه هستیم، تجزیه تحلیل و واکشی اطلاعات است. هر اطلاعاتی که از شبکه استخراج می‌شود منجر به شناخت بیشتر ما از شبکه خواهد شد. بررسی خصوصیات شبکه‌های ناهمگن، چندلایه/چندگانه هندسی و غیرهندسی نیز بسیار با اهمیت هستند. هم‌چنین بررسی شبکه‌های ناهمگنی که از نوع چندلایه یا چندگانه باشند هم می‌تواند هم پیچیده و هم بسیار حائز اهمیت باشد. در این جا نمونه‌ای از این خواصی که می‌توان با تعبیه سازی این گونه گراف‌ها مورد بررسی قرار داد را توضیح می‌دهیم:

- **شناسایی جماعت‌های محلی**<sup>۲۷</sup>: راه حل‌های مختلفی که برای حل این مساله مورد استفاده قرار گرفته است را می‌توان به سه دسته کلی تقسیم‌بندی کرد: روش‌های مبتنی بر مسطح سازی<sup>۲۸</sup> که در آن اطلاعات همه لایه‌ها در یک لایه جمع<sup>۲۹</sup> می‌شود و سپس از الگوریتم‌های کلاسیک تک‌لایه استفاده می‌شود [۱۵]، روش‌های مبتنی بر تجمیع<sup>۳۰</sup> که در آن ابتدا روی هر لایه به صورت مستقل شناسایی تشکل انجام می‌شود و در انتها این اطلاعات با یکدیگر تجمیع می‌شوند-از مزایای این روش می‌توان به حذف اطلاعات اضافی در لایه‌ها اشاره کرد- اما برای تجمیع این اطلاعات روش کارسازی ارائه نشده است [۱۶]، در روش مستقیم<sup>۳۱</sup> فرآیند شناسایی تشکل یکباره و بدون مسطح‌سازی انجام می‌شود. مثلاً در [۱۷] یک معیار ماژولاریتی جدید مبتنی بر گراف مولتی-پلکس تعریف و با الگوریتم Louvain ترکیب شده است. در [۱۸] تلاش شده است تا با در نظر گرفتن همزمان ساختار گرافی و هم‌چنین علایق هر فرد که بر اساس آنالیز محتوای منتشر شده از هر کاربر به دست می‌آید، روی تک شبکه عملیات شناسایی جماعت‌ها انجام شود. هم‌چنین در [۱۹] الگوریتم جدیدی مبتنی بر

<sup>27</sup> Local community detection

<sup>28</sup> Flattening methods

<sup>29</sup> collapse

<sup>30</sup> Aggregation methods

<sup>31</sup> Direct methods

قدم‌زنی تصادفی<sup>۳۲</sup> برای شناسایی جماعت‌ها در گراف‌های چندگانه آورده شده است. برای بهبود می‌توان شرایطی را در نظر گرفت که اولاً نودهای موجود در گراف‌های چندگانه دقیقاً مشابه نباشند (که در دنیای واقعی این چنین است) و ثانیاً از سایر الگوریتم‌ها مثل یادگیری عمیق<sup>۳۳</sup> و شبکه کانولوشن گرافی<sup>۳۴</sup> برای شناسایی جماعت‌ها در شبکه‌های چندگانه استفاده نمود. زمانی که گراف‌های موجود در هر لایه قابلیت ناهمگن بودن را داشته باشند عملاً برای استفاده کردن از الگوریتم‌های سنتی ناچاریم در ابتدا گراف ناهمگن را به همگن تبدیل کنیم (تفاوت انواع موجود حذف خواهد شد) و سپس پردازش مورد نظر را اعمال کنیم. در این شرایط علاوه بر اینکه اطلاعات موجود در گراف را دور ریخته‌ایم، شاید بدلیل حذف برخی روابط به گونه‌ای نویز هم اضافه کرده باشیم. به همین دلیل در این طرح پژوهشی رویکرد استفاده از شبکه‌های عصبی گراف ناهمگن را برای این نوع شبکه‌های ناهمگن چند لایه مورد بررسی قرار خواهیم داد تا بتوانیم از حداکثر داده‌های موجود به صورت محلی و سراسری استفاده کنیم.

- **شناسایی نودهای خاص شبکه:** یکی از مسائل مهم، شناسایی نودهای تاثیرگذار<sup>۳۵</sup> و نودهای هاب است. در گذشته این مساله روی تک گراف‌ها انجام شده است اما تا کنون فعالیتی برای انجام این هدف روی گراف‌های ناهمگن ساده، چندگانه و چندلایه به صورت هم زمان انجام نشده است. این مساله زمانی پر رنگ‌تر می‌شود که ممکن است برخی از انواع نودها در لایه‌های میانی و بین چند لایه بتوانند تصور شوند. برای مثال فرض کنیم با داده‌های شبکه‌های اجتماعی مواجه هستیم که نودهای آن از نوع اکانت، تصویر و متن پیام باشد. در این حالت متون منتشر شده و همچنین تصاویر می‌تواند در خارج از لایه‌های خاص نوع شبکه‌ای اجتماعی قرار بگیرد. آنالیز ناهمگن چند لایه این نوع داده می‌تواند حداکثر اطلاعات را از گراف استخراج کند. مثلاً می‌توانیم با تعبیه سازی نودهای تصویر، گروه بندی موضوعی روی تصاویر استفاده شده داشته باشیم بدون آن که حتی پردازشی از نوع بینایی ماشین انجام داده باشیم.
- **پیش بینی ایجاد یال جدید در شبکه<sup>۳۶</sup>:** یکی از مسائل رایج در آنالیز شبکه‌های اجتماعی، تخمین ایجاد یال جدید است. در گذشته این مساله صرفاً روی اطلاعات یک گراف انجام شده است درحالی که با استفاده از بستر شبکه‌های چندگانه می‌توان از دینامیک موجود در سایر شبکه‌ها، برای تخمین دقیق‌تر استفاده نمود. در [۲۰] تلاش شده است تا بر اساس شبکه‌های چندلایه، تعاملات آینده بین مولفین مختلف پیش‌بینی شود. در این تحقیق در یک لایه اسم مولفین و در لایه‌های دیگر انواع مختلفی از تعاملات بین آن‌ها قرار می‌گیرد. یکی از مواردی که می‌تواند برای بهبود این مساله در نظر گرفته شود استفاده از اطلاعات موجود در سایر شبکه‌های اجتماعی هر مؤلف است. چون معمولاً مولفینی که دارای مشترکاتی در بقیه حوزه‌ها هستند در آینده احتمالاً بیشتر در مباحث علمی باهم ارتباط برقرار می‌کنند.
- **یادگیری شبه نظارت شده<sup>۳۷</sup>:** در این مساله برخی از نودهای شبکه دارای لیبل هستند. هدف، تخمین لیبل برای سایر نودها است. برای حل این مساله در گذشته و با در نظر گرفتن شرایط خاص پژوهش‌هایی انجام شده است [۲۱]. اما در شرایطی که گراف ارتباطات به صورت ناهمگن چندگانه باشد و یا گراف ارتباطات وزن‌دار و جهت‌دار باشد فعالیتی انجام نشده است. هم‌چنین می‌توان دینامیک فعالیت کاربران در طول زمان را هم در نظر گرفت تا نتایج دقیق‌تری بدست آید.
- **شناسایی اخبار جعلی<sup>۳۸</sup>:** این موضوع را می‌توان از منظر دیگری به شناسایی انتشار شایعات<sup>۳۹</sup> نیز نزدیک دانست. به دلیل گسترش روزافزون حضور اقشار جامعه در فضای مجازی، میزان صداقت و انتشار اخبار درست بسیار حائز اهمیت است. به

<sup>32</sup> Random walk

<sup>33</sup> Deep learning

<sup>34</sup> Graph convolutional networks

<sup>35</sup> Influencer

<sup>36</sup> Edge prediction

<sup>37</sup> Semi supervised learning

<sup>38</sup> Fake News Detection

<sup>39</sup> Rumor propagation

عنوان مثال در سال ۱۳۹۲ پس از هک اکانت توییتر خبرگزاری آسوشیتدپرس و انتشار خبری مبنی بر حمله به کاخ سفید، ارزش سهام بازارهای بورس آمریکا موقتاً افت کرد که در شدیدترین آن‌ها داوجونز ۱۵۰ رقم افت داشت [۲۲].

این مساله تاکنون از منظر شبکه‌های ناهمگن یا چندگانه مورد بررسی قرار نگرفته است و اکثر پژوهش‌هایی که تا الان انجام شده است به صورت خاص منظوره و صرفاً مبتنی بر پردازش زبان طبیعی بوده است. هدف آنست که اولاً هر محتوای متنی در شبکه‌های اجتماعی به کاربران آن منتسب باشد و ثانیاً بتوان هر فرد یا شبکه‌ای از افراد را در این گراف چندگانه تحلیل و برچسب‌گذاری (افراد صادق، افراد متوسط و راویان ضعیف) کرد. بر این اساس نودهای گراف حداقل دو نوع کاربران و متن‌های منتشره هستند که هر نوع نود می‌تواند خصوصیات متنوعی داشته باشد. یکی از چالش‌هایی که در این حوزه وجود دارد فقدان دیتاست‌های غنی برای آموزش مدل است، از این رو در [۲۳] تلاش شده است تا مبتنی بر آموزش شبکه نظارت شده، کمبود داده‌های آموزشی را جبران کند. در این مقاله ابتدا هر کلمه از هر متن، با الگوریتم GloVe تعبیه شده و میانگین بردارهای تعبیه شده هر متن به عنوان بردار متن در نظر گرفته می‌شود. سپس گرافی متشکل از هر متن خبر (نود) ساخته می‌شود و با ارزیابی فاصله بین هر دو متن طبق معیار word mover's distance بین نودهای مشابه یال در نظر گرفته می‌شود. در ادامه ۳ نوع نود خواهیم داشت، نودهای حقیقی، نودهای جعلی و نودهای بدون برچسب. مبتنی بر الگوریتم GCN و انتشار لیبل که سعی می‌شود برای نودهای بدون برچسب، برچسب‌گذاری انجام شود.

- **خلاصه‌سازی گراف<sup>۴۰</sup>:** بر اساس هدف مورد نظر، برای خلاصه‌سازی گراف روش‌های مختلفی می‌توان به کار برد. به عنوان مثال یک روش استفاده از اطلاعاتی است که از شناسایی جماعت‌های محلی به دست آمده است. روش دیگر ساخت یک پوشاننده<sup>۴۱</sup> از گراف است که تقریبی از گراف اصلی را تولید می‌کند [۲۴]. این روش می‌تواند زیرگرافی از گراف اولیه بسازد که فاصله‌ی بین رئوس (در شبکه‌های هندسی فاصله‌ی اقلیدسی و در شبکه‌های غیرهندسی فاصله‌ی لینکی) را با تقریب خوبی حفظ کند.

- **ساخت گراف ناهمگن چند لایه:** یکی از مسایل مهمی که در این حوزه وجود دارد تبدیل مسایل کاربردی به گراف‌های درخور است که به وسیله گراف حاصل شده بتوانیم تحلیل‌های ارزشمندی روی مساله مورد نظر ارائه دهیم. به عنوان مثال تا به حال گرافی چند لایه که هر لایه می‌تواند همگن یا ناهمگن باشد برای مسائل در نظر گرفته نشده است که اگر بتوانیم ساخت چنین گرافی را دنبال کنیم مسلماً با تحلیل آن اطلاعات نهفته‌ای از مساله مورد نظر را کشف خواهیم کرد.

- **ادغام نودها:** یکی از ایده‌هایی که برای شناسایی نودهای خاص می‌تواند مفید باشد رویکرد ادغام نودها باشد. از ادغام در رویکردهای مختلفی از یادگیری عمیق استفاده می‌شود، اما شبکه عصبی گراف برای ادغام سازوکار قطعی ندارد و وابسته به مساله ایده‌های مختلفی ارائه شده است [۲۵]. راهکارهای ارائه شده عمدتاً در حوزه گراف‌های همگن کارایی دارند و برای گراف‌های ناهمگن فعالیت جدی انجام نشده است. در این طرح پژوهشی یکی دیگر از حوزه‌هایی که روی آن تمرکز خواهد شد استفاده از این رویکرد برای مصارف خاص مانند شناسایی نودهای خاص، بهبود دقت الگوریتم و فرآیند آموزش مدل، خوشه‌بندی گراف و ... خواهد بود.

- **فرامسیرهای احتمالی:** همانگونه که در بالا اشاره شد، یکی از رویکردهای اصلی مواجه شدن با گراف‌های ناهمگن استفاده از فرامسیرها است. در پژوهش‌های قبلی تلاش کردیم که از فرامسیرهای احتمالاتی استفاده کنیم و مبتنی بر آن برخی از تسک‌های رایج این حوزه را بررسی کنیم. در ادامه تلاش خواهیم کرد تا مبتنی بر لایه‌های مختلف گراف هم فرامسیر طراحی شود و عملاً فرآیند انتقال بین لایه‌های گراف چندلایه ناهمگن بر اساس نوعی از فرامسیرها و حرکت در هر لایه مبتنی انواع دیگری از متاپت‌ها باشد.

<sup>40</sup> Graph compressing

<sup>41</sup> Spanner

- [1] R. Churchill and L. Singh, "Topic-noise models: Modeling topic and noise distributions in social media post collections," in *2021 IEEE International Conference on Data Mining (ICDM)*. IEEE, 2021, pp. 71–80.
- [2] Y. Li, R. Yu, C. Shahabi, and Y. Liu, "Diffusion convolutional recurrent neural network: Data-driven traffic forecasting," *arXiv preprint arXiv:1707.01926*, 2017.
- [3] J. Atwood and D. Towsley, "Diffusion-convolutional neural networks," *Advances in neural information processing systems*, vol. 29, 2016.
- [4] C. Shi, Y. Li, J. Zhang, Y. Sun, and S. Y. Philip, "A survey of heterogeneous information network analysis," *IEEE Transactions on Knowledge and Data Engineering*, vol. 29, no. 1, pp. 17–37, 2016.
- [5] V. Moscato and G. Sperli, "A survey about community detection over on-line social and heterogeneous information networks," *Knowledge-Based Systems*, vol. 224, p. 107112, 2021.
- [6] X. Wang, D. Bo, C. Shi, S. Fan, Y. Ye, and S. Y. Philip, "A survey on heterogeneous graph embedding: methods, techniques, applications and sources," *IEEE Transactions on Big Data*, 2022.
- [7] Y. Dong, N. V. Chawla, and A. Swami, "metapath2vec: Scalable representation learning for heterogeneous networks," in *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining*, 2017, pp. 135–144.
- [8] T.-y. Fu, W.-C. Lee, and Z. Lei, "HIN2vec: Explore meta-paths in heterogeneous information networks for representation learning," in *Proceedings of the 2017 ACM Conference on Information and Knowledge Management*, 2017, pp. 1797–1806.
- [9] X. Li, Y. Wu, M. Ester, B. Kao, X. Wang, and Y. Zheng, "Semi-supervised clustering in attributed heterogeneous information networks," in *Proceedings of the 26th international conference on world wide web*, 2017, pp. 1621–1629.
- [10] X. Fu, J. Zhang, Z. Meng, and I. King, "MAGNN: Metapath aggregated graph neural network for heterogeneous graph embedding," in *Proceedings of The Web Conference*, 2020, pp. 2331–2341.
- [11] A. G. Carranza, R. A. Rossi, A. Rao, and E. Koh, "Higher-order clustering in complex heterogeneous networks," in *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2020, pp. 25–35.
- [12] A. Grover and J. Leskovec, "node2vec: Scalable feature learning for networks," in *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*, 2016, pp. 855–864.
- [13] B. Perozzi, R. Al-Rfou, and S. Skiena, "DeepWalk: Online learning of social representations," in *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2014, pp. 701–710.
- [14] Y. Chang, C. Chen, W. Hu, Z. Zheng, X. Zhou, and S. Chen, "MEGNN: Meta-path extracted graph neural network for heterogeneous graph representation learning," *Knowledge-Based Systems*, vol. 235, p. 107611, 2022.
- [15] Kuncheva, Zhana, and Giovanni Montana. "Community detection in multiplex networks using locally adaptive random walks", *Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, 2015.
- [16] De Domenico, Manlio, et al. "Identifying modular flows on multilayer networks reveals highly overlapping organization in interconnected systems", *Physical Review X*, 5.1, 2015.
- [17] Pramanik, Soumajit, et al. "Discovering community structure in multilayer networks", *2017 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, 2017.
- [18] Wang, Lidong, Keyong Hu, Yun Zhang, and Shihua Cao. "Factor graph model-based user profile matching across social networks." *IEEE Access* 7, 2019.
- [19] Fani, Hossein, Eric Jiang, Ebrahim Bagheri, Feras Al-Obeidat, Weichang Du, and Mehdi Kargar. "User community detection via embedding of social network structure and temporal content." *Information Processing & Management* 57, 2, 2020.
- [20] Tuninetti, Marta, Alberto Aleta, Daniela Paolotti, Yamir Moreno, and Michele Starnini. "Prediction of scientific collaborations through multiplex interaction networks", *arXiv preprint arXiv:2005.04432*, 2020.
- [21] Chen, Zitai, et al. "Tensor decomposition for multilayer networks clustering", *Proceedings of the AAAI Conference on Artificial Intelligence*. Vol. 33. No. 01. 2019.
- [22] <https://www.amazon.com/s?k=9783319546575&i=stripbooks&linkCode=qs>, p.172.
- [23] Meel, Priyanka, and Dinesh Kumar Vishwakarma. "Fake News Detection using Semi-Supervised Graph Convolutional Network." *arXiv preprint arXiv:2109.13476*, 2021.
- [24] S. Aghamolaei, F. Baharifard, M. Ghodsi. "Geometric spanners in the MapReduce model" *In International Computing and Combinatorics Conference*, pp. 675-687. 2018.
- [25] Grattarola, Daniele, Daniele Zambon, Filippo Maria Bianchi, and Cesare Alippi. "Understanding pooling in graph neural networks." *IEEE Transactions on Neural Networks and Learning Systems*, 2022.