

Rumor Detection on Social Networks Based on the Degree Distribution Analysis in Step-by-Step Propagation Subgraphs

M. Khosravi, H. Shirazi*, K. Dadashtabar, A. Hashemi Gholpayghani

*Professor, Electrical and Computer University Complex, Malik Ashtar University of Technology, Tehran, Iran

(Received: 08/12/2021, Accepted: 14/03/2022)

ABSTRACT

With the expansion of social networks and the increase in their users, these networks have become an effective medium for publishing news and various content. Therefore, new challenges have been created in this space, one of the most important of which is spreading rumors and false information. Rumors are moving at an incredible rate in society due to their appeal and attraction. Their spread can have many destructive effects on human societies and sometimes have irreparable consequences. For this reason, many researchers today deal with rumors in these networks. The purpose of this article is to provide a new method that can detect rumors without user information and post content analysis, and only according to the post propagation subgraph. Therefore, the degree distribution of the propagation graphs in the rumored and non-rumored models is examined. Then different classifiers were used to distinguish between these two modes. The Random Forest classifier gives better results than others. Since this method can finally detect rumors within three steps after propagation, this method has a good performance in terms of time.

Keywords: Social networks, Rumor, Publication, Graph.

* Corresponding Author Email: Shirazi@mut.ac.ir

تشخیص شایعه در شبکه‌های اجتماعی مبتنی بر تحلیل الگوی فراوانی درجه رئوس در زیرگراف‌های گام‌به‌گام انتشار

مریم خسروی^۱، حسین شیرازی^{۲*}، کوروش داداش‌تبار^۳، علیرضا هاشمی گلپایگانی^۴

۱- دانشجوی دکتری، ۲- استاد، ۳- استادیار، مجتمع دانشگاهی برق و کامپیوتر،

۴- استادیار، دانشکده کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی امیرکبیر، تهران، ایران

(دریافت: ۱۴۰۰/۰۹/۱۷، پذیرش: ۱۴۰۰/۱۲/۲۳)

چکیده

با گسترش شبکه‌های اجتماعی و افزایش تعداد کاربران آن‌ها، چالش‌های جدیدی در این فضا ایجاد شده است. یکی از مهم‌ترین چالش‌ها انتشار شایعات و اطلاعات نادرست است که گسترش آن‌ها می‌تواند تأثیرات مخرب زیادی را بر جوامع انسانی بگذارد و گاهی عواقب جبران‌ناپذیری را نیز به بار آورد. به همین دلیل امروزه پژوهش‌های فراوانی به تشخیص شایعات در این شبکه‌ها می‌پردازند. در اکثر پژوهش‌هایی که از روش بررسی گراف انتشار برای تشخیص شایعات استفاده کرده‌اند، نیاز به درگیر شدن با پیچیدگی‌های پردازش زبان یا تحلیل ویژگی‌های کاربر است و به دلیل پیچیدگی تحلیل گراف‌های انتشار شایعات تا کنون از این روش به‌تنهایی برای تشخیص شایعه استفاده نشده و نیاز به استفاده از سایر ویژگی‌ها یا تحلیل متن بوده است. از این‌رو، هدف از این مقاله، ارائه روش جدیدی مبتنی بر زیرگراف انتشار پست به منظور تشخیص شایعات است؛ بنابراین فراوانی درجه رئوس گراف‌های انتشار در مدل‌های شایعه و غیرشایعه مورد بررسی قرار گرفت و یک بردار هشت‌تایی با توجه به این ویژگی زیرگراف‌های انتشار استخراج شد. سپس از دسته‌بندی‌کننده‌های مختلف به منظور تشخیص تمایز بین این دو حالت با توجه به بردار هشت‌تایی استفاده شد. پس از ارزیابی، مشخص شد که دسته‌بندی‌کننده جنگل تصادفی بر روی مجموعه داده PHEME نتیجه بهتر و دقتی حدود ۰/۸۴ دارد. از آنجایی که این روش نهایتاً در چهار گام پس از انتشار قادر به تشخیص است، از لحاظ زمانی نیز کارایی مناسبی دارد.

کلیدواژه‌ها: شبکه‌های اجتماعی، شایعه، انتشار، گراف

۱- مقدمه

با گسترش تعداد کاربران شبکه‌های اجتماعی برخط، این شبکه‌ها تبدیل به رسانه تأثیرگذاری به‌منظور به اشتراک گذاشتن اطلاعات شدند و افراد برای تصمیم‌گیری‌هایشان در مورد یک موضوع خاص مانند مباحث سیاسی، تحت تأثیر دوستان خود هستند. علاوه بر آن نیز شبکه‌های اجتماعی از جمله منابع مهم خبر برای بیشتر مردم محسوب می‌شوند. از این‌رو، اطلاعات نادرست موجود در این شبکه‌ها، باعث تأثیر غلط در جمعیت زیادی از مردم خواهد شد و انتقال آلودگی‌های مختلف بین دوستان در این شبکه‌ها رایج است.

انتشار شایعه و اخبار نادرست از زمان‌های گذشته به‌عنوان یک مسئله اجتماعی و روانی با ابعاد گسترده بوده است که در مواقع بحرانی مانند جنگ بیشتر حائز اهمیت می‌شود. در گذشته شایعات بیشتر از طریق گفت‌وگو، روزنامه‌ها، رادیو و تلویزیون منتشر می‌شد اما امروزه به دلیل قابلیت‌های موجود در شبکه‌های اجتماعی، این شبکه‌ها نیز به‌عنوان ابزاری برای انتشار شایعه تبدیل شده‌اند. شایعه به دلیل گیرایی

با گسترش روزافزون استفاده از اینترنت در سال‌های اخیر، شبکه‌های اجتماعی نقش مؤثری در گسترش اطلاعات و نظرات یافته‌اند و به هر فرد امکان اشتراک‌گذاری اطلاعاتش را می‌دهند. این امر باعث ایجاد مشکلات جدیدی در این فضا گشته است که از جمله آن می‌توان به حملات امنیتی اشاره کرد که در صورت برآورده نشدن اهداف امنیتی مانند محرمانگی، جامعیت و دسترسی‌پذیری ایجاد می‌شوند. امروزه یکی از حملات امنیتی موجود در این شبکه‌ها حملات معنایی است. در این حملات در واقع هدف این است که به‌منظور ایجاد تغییر در فعالیت کاربر، بر روی احساسات او تأثیر گذاشته شود که از طریق انتشار شایعات و اطلاعات نادرست و دروغ ایجاد می‌شود. انتشار اطلاعات نادرست و شایعات می‌تواند به‌صورت عمدی یا سهوی توسط کاربر صورت گیرد [۱].

* رایانامه نویسنده مسئول: Shirazi@mut.ac.ir

۲- پیشینه پژوهش

شایعات یکی از موضوعات علوم اجتماعی، در طول تاریخ بوده است تا این که در زمان جنگ جهانی دوم علاقه به روان‌شناسی شایعه و کنترل آن افزایش یافت. در آن زمان پژوهش اصلی توسط آلپورت و پستمن انجام گرفت و یکی از دلایل آن پژوهش این بود که روحیه مردم و امنیت جامعه توسط گسترش شایعات تهدید شده بود. پس از گسترش اینترنت و ایجاد بستر شبکه‌های اجتماعی که امکان نشر شایعات را بیشتر فراهم می‌آورد، تشخیص و جلوگیری از انتشار آن توجه بسیاری از پژوهشگران را به خود جلب کرده است.

پژوهش‌های تشخیص شایعه را می‌توان به چهار دسته کلی تقسیم‌بندی کرد. دسته اول پژوهش‌ها به بررسی شایعات از دیدگاه روان‌شناختی پرداخته‌اند مقاله‌های [۲ و ۵] و [۶ و ۷] با بررسی ویژگی‌های روان‌شناختی سعی در پیاده‌سازی روشی به‌منظور تشخیص اطلاعات نادرست در شبکه‌های اجتماعی برخط دارند. از ایرادات این روش این است که ویژگی‌های روانی ممکن است در جوامع مختلف تأثیرات متفاوتی داشته باشد و قابل تعمیم به همه شبکه‌های اجتماعی در ملیت‌های مختلف نباشد.

دسته دوم نیز پژوهش‌هایی هستند که از روش‌های زبان‌شناسی برای تشخیص شایعه استفاده می‌کردند. در واقع در این پژوهش‌ها ابتدا محتوای شایعات موجود مورد بررسی قرار می‌گیرد و با استفاده از ویژگی‌های مشترک زبان‌شناسی که وجود دارد امکان تشخیص شایعه را فراهم می‌آورد. در دهه‌های قبل از روش‌های سنتی پردازش زبان به‌منظور بررسی ویژگی‌های خاص زبانی موجود در شایعات استفاده می‌شد مانند مقالات [۸ و ۹]، اما اخیراً در کارهای جدید مانند [۱۰-۱۴] بیشتر از یادگیری عمیق به‌منظور بررسی زبان بهره گرفته می‌شود. مشکل این روش درگیر شدن با پیچیدگی‌های پردازش زبان و تحلیل محتوا است و گاهی از زبانی به زبان دیگر تفاوت دارد.

دسته سوم پژوهش‌هایی هستند که هدفشان ارائه مدل‌های انتشار شایعه است. برخی از این پژوهش‌ها مانند [۱۵-۱۷] با استفاده از مدل‌های انتشار بیماری سعی در مدل‌سازی انتشار شایعه یا تشخیص منبع دارند. مدل‌های خاصی بر اساس پدیده‌های دیگر مانند پدیده‌های فیزیکی ارائه داده‌اند که از این دسته می‌توان به [۱۸ و ۱۹] اشاره کرد. دسته دیگری هم مانند [۲۰-۲۲] مدل‌های انتشاری مبتنی بر مدل‌های انتشار اطلاعات مانند آشناری مستقل و آستانه خطی [۲۳] ارائه داده‌اند که معمولاً از آن‌ها برای کنترل انتشار شایعه استفاده شده است و کمتر مدل‌سازی انتشار شایعه را با آن‌ها انجام داده‌اند. در این روش‌ها بیشتر به مدل کردن فرایند انتشار پرداخته می‌شود و برای تشخیص شایعه کمتر کاربرد دارد.

و کشتی که دارد با سرعتی باورنکردنی در جامعه حرکت می‌کند و گسترش آن می‌تواند تأثیرات مخرب زیادی را بر جوامع انسانی بگذارد و گاهی عواقب جبران‌ناپذیری را نیز به بار آورد، از این‌رو، تشخیص شایعه و جلوگیری از انتشار آن از دیرباز حائز اهمیت بوده است.

تاکنون پژوهش‌های بسیاری در زمینه بررسی شایعات انجام گرفته است. یکی از پژوهش‌های اولیه را می‌توان، پژوهش آلپورت و پستمن بعد از جنگ جهانی دوم در حوزه روان‌شناسی شایعه [۲] دانست. آن‌ها شایعه را عبارت از داستانی تعریف کردند که درستی آن مشخص نیست و به‌سرعت از شخصی به شخص دیگر در گردش است. در آن دهه مطالعات دیگری نیز شکل گرفت و سپس این مطالعات خاموش شد. پس از آن در اواخر دهه ۱۹۶۰ و ۱۹۷۰، به این موضوع گرایش ایجاد شد. در دو دهه اخیر و با رشد شبکه‌های اجتماعی نیز پژوهش‌های جدیدی در این زمینه شده است [۳].

در اکثر این روش‌ها برای تشخیص شایعات ویژگی‌های زبانی را در نظر می‌گیرند که باعث درگیر شدن با مشکلات پردازش زبان و تحلیل محتوا می‌شود. به دلیل پیچیده بودن تحلیل گراف‌های انتشار، تعریف ویژگی‌های مشخص مبتنی بر ساختار انتشار دشوار است [۴]. از این‌رو، تاکنون پژوهشی در این زمینه انجام نگرفته است که فقط ویژگی‌هایی از زیرگراف انتشار را استخراج کند و بدون نیاز به اطلاعات دیگر مانند اطلاعات مربوط به کاربر، بتواند تمایز بین شایعه یا غیرشایعه را تشخیص دهد.

در این پژوهش هدف این است که روش جدیدی ارائه شود که تنها با استفاده از ویژگی‌های زیرگراف انتشار و بدون نیاز به بررسی محتوای شایعات و ویژگی‌های کاربر قادر به تشخیص آن‌ها باشد و در زمان بهینه گسترش آن را تشخیص دهد. از این‌رو، سؤالات اصلی تحقیق بدین صورت است:

- آیا می‌توان تنها از طریق بررسی گراف انتشار پست، شایعه بودن یا نبودن آن را تشخیص داد؟
- چطور می‌توان ویژگی‌هایی را از گراف انتشار استخراج کرد که تحلیل کاملی از گراف نشان دهد؟
- دسته‌بندی‌کننده مناسب برای مقایسه گراف‌های انتشار شایعات و غیر شایعات چیست؟

در ادامه مقاله در بخش دوم به بررسی کارهای مرتبط پیشین پرداخته می‌شود. سپس در بخش سوم روش پیشنهادی بیان می‌شود و در بخش چهارم نیز چگونگی تعریف آزمایش‌ها و نتایج به‌دست‌آمده بیان و تحلیل می‌شود. در نهایت در بخش آخر به جمع‌بندی و نتیجه‌گیری پرداخته خواهد شد.

در این پژوهش برخلاف پژوهش‌های گذشته روشی مطرح خواهد شد که برای اولین بار تنها با توجه به گراف انتشار و بدون نیاز به تحلیل محتوا و اطلاعات مربوط به کاربر، روشی برای تشخیص شایعات ارائه دهد. در این روش به بررسی توزیع درجه زیرگراف انتشار و استخراج ویژگی‌های مرتبط با آن در شایعات پرداخته می‌شود تا از این طریق بتوان تفاوت بین شایعات و غیر شایعات را تنها با توجه به الگوی انتشار و بدون نیاز به سایر ویژگی‌های زبانی یا کاربر تشخیص داد. این روش قابل تعمیم به همه جوامع است و نیاز به درگیری با پیچیدگی‌های زبانی و روان‌شناسی نیست. علاوه بر آن قابلیت پیاده‌سازی برای همه انواع شبکه‌های اجتماعی را دارد.

۳- روش پیشنهادی

همان‌گونه که ذکر شد، هدف از این پژوهش این است که بدون نیاز به اطلاعات کاربر و تحلیل محتوا روشی به‌منظور تشخیص شایعه در شبکه‌های اجتماعی، ارائه شود. از این‌رو، ابتدا زیرگراف انتشار هر پست مشخص می‌شود و ویژگی‌های زیرگراف انتشار که از طریق چگونگی توزیع فراوانی درجه استخراج می‌شود، به یک دسته‌بندی‌کننده داده می‌شود تا شایعه بودن یا نبودن پست منتشرشده، تشخیص داده شود که در این بخش به توضیح بیشتر این روش پرداخته خواهد شد.

۳-۱- بیان ریاضی مسئله

در این پژوهش شبکه اجتماعی به صورت گراف $G=(V,E)$ در نظر گرفته می‌شود که V نشان‌دهنده گره‌ها (کاربران) و E نشان‌دهنده روابط بین آن‌ها است. این کاربران توانایی انتشار متن دارند که این متن ممکن است توسط خود فرد تولید شده باشد یا اینکه آن را بازنشر داده باشد. هر فرد تعدادی دنبال‌کننده دارد که متونی را که منتشر می‌کند، می‌بینند و از طرف دیگر تعدادی افراد را دنبال می‌کند که قادر به دیدن متون انتشار داده شده توسط آن‌ها می‌باشد. پستی که کاربر v منتشر می‌کند را با c_v نشان می‌دهند. هدف تشخیص شایعه بودن یا نبودن پست c_v از طریق به دست آوردن زیرگراف انتشار پست c_v می‌باشد که توسط فرد یا افراد منتشرکننده شایعه ایجاد می‌شود و با نام $G'(V',E')$ نشان می‌دهند به صورتی که $V' \subseteq V$ و $E' \subseteq E$ است.

۳-۲- استخراج ویژگی‌ها

تشخیص شایعه با استفاده از مدل ذکرشده، به صورت یک مسئله دسته‌بندی در نظر گرفته می‌شود. از این‌رو، نیاز است دسته‌بندی‌کننده بتواند با استفاده از تفاوت زیرگراف انتشار شایعات در چند گام اول از غیر شایعات، آن‌ها را تشخیص دهد.

دسته آخر که این پژوهش نیز در این دسته است، پژوهش‌هایی هستند که الگوی انتشار پست را بررسی می‌کنند و سپس با استفاده از روش‌های دستی استخراج ویژگی‌ها یا یادگیری عمیق سعی در تشخیص شایعات دارند. از آنجایی که کار با ساختار گراف برای یادگیری دشوار است هر کدام از مقالات در این حوزه سعی داشته‌اند که برخی از ویژگی‌های گراف را بدین منظور استخراج و استفاده کنند.

یکی از این پژوهش‌ها مقاله [۴] است که مبتنی بر یادگیری هسته^۱ با استفاده از درخت‌های انتشار می‌باشد. برای استخراج الگو، گسترش هر پست را با یک درخت انتشار نشان می‌دهد. یک درخت انتشار نیز گسترش هر پست را با الگوهای ساختاری پیچیده رمز می‌کند و اطلاعات در مورد محتوا، کاربر و زمان را با گره‌های درخت یکدست می‌کند رمز می‌کند. در این روش برای بالا بردن دقت نیاز به استفاده از ویژگی‌های محتوا و اطلاعات مربوط به کاربر نیز می‌باشد.

در [۲۴] نیز با استفاده از شبکه عصبی عمیق و ویژگی‌های الگوی انتشار و محتوای متن سعی در تشخیص شایعه دارد. در این مقاله تعداد لایه‌های انتشار پست را بررسی کرده‌اند که با افزایش آن احتمال شایعه بودن بیشتر می‌شود و از این ویژگی برای یادگیری استفاده می‌شود. ایراد این روش این است که مواردی را برای یادگیری ساختار گراف استفاده کرده است که به خوبی نمی‌تواند ویژگی‌های اصلی گراف را توصیف کند.

یکی از پژوهش‌های نزدیک‌تر به این مقاله، مرجع [۲۵] می‌باشد که از گراف برای مدل کردن فرایند انتشار استفاده می‌کند به این صورت که یک پست گره و ارتباط بین دو پست یال می‌باشد. سپس از یک شبکه عصبی گراف کانولوشنی برای یادگیری بردارها، که شامل ویژگی‌های انتشار و محتوا می‌باشد استفاده می‌کند. مشکل این روش این است که به تمامی اطلاعات در طول فرایند انتشار نیاز دارد و به‌عنوان مثال با نبودن پست‌های پاسخ دیگر قادر به تشخیص شایعه نیست.

این مقالات اگرچه از ویژگی‌های انتشار استفاده می‌کنند اما برای بالا بردن دقت نیاز به استفاده از ویژگی‌های زبانی نیز دارند و همین موضوع آن‌ها را به تحلیل محتوا و پیچیدگی‌های مرتبط با آن نیازمند می‌کند که ممکن است وابسته به نوع زبان باشد. در واقع همان‌گونه که ذکر شد به دلیل دشوار بودن استخراج ویژگی‌های مرتبط به گراف انتشار و کامل نبودن این ویژگی‌ها نیاز به استفاده از سایر ویژگی‌ها مانند اطلاعات کاربر یا محتوا نیز در این مقالات وجود دارد.

¹ Kernel Learning

$$P_G(d) = P(D(v) = d); v \in V(G) \quad (1)$$

$$\mu_G = \sum_{d=\min_G(D(v))}^{\max_G(D(v))} d \times P_G(d) \quad (2)$$

$$\sigma_G = \sqrt{\sum_{d=\min_G(D(v))}^{\max_G(D(v))} P_G(d) \times (d - \mu_G)^2} \quad (3)$$

$$R_G(r) = \begin{cases} [\min_G(D(v)), (\mu_G - \sigma_G)] \\ [(\mu_G - \sigma_G), \mu_G] \\ [\mu_G, (\mu_G + \sigma_G)] \\ [(\mu_G + \sigma_G), \max_G(D(v))] \end{cases} \quad (4)$$

$$\|R_G(r)\| = (\max(\text{right}(R_G(r)) - \text{left}(R_G(r))), 0) \quad (5)$$

$$I_G = \begin{cases} \left[\text{left}\left(R_G\left(\left\lfloor \frac{i}{2} \right\rfloor\right)\right), \text{left}\left(R_G\left(\left\lfloor \frac{i}{2} \right\rfloor\right)\right) + \frac{|R_G\left(\frac{i}{2}\right)|}{2} \right] \\ i \text{ is odd} \\ \left[\text{left}\left(R_G\left(\left\lfloor \frac{i}{2} \right\rfloor\right)\right) + \frac{|R_G\left(\frac{i}{2}\right)|}{2}, \text{right}\left(R_G\left(\left\lfloor \frac{i}{2} \right\rfloor\right)\right) \right] \\ i \text{ is even} \end{cases} \quad (6)$$

$$IDP_G = P(\text{left}(I) \leq D(v) < \text{right}(I)); v \in V(G) \quad (7)$$

$$Q(G) = \langle IDP_G(I_G(i)) \rangle_{i=1, \dots, 8} \quad (8)$$

۳-۳- دسته‌بندی داده‌ها

در این پژوهش برای تشخیص تفاوت‌های توزیع درجه مدل‌ها چند نمونه از دسته‌بندی‌کننده‌های رایجی که برای تشخیص شایعات استفاده شده است مورد ارزیابی قرار گرفت. این دسته‌بندی‌کننده‌ها در ادامه مطرح می‌شود.

- دسته‌بندی‌کننده بی‌زین ساده گاوسی^۱ (GNB): این دسته‌بندی‌کننده مبتنی بر تئوری بی‌ز است و یک دسته‌بندی‌کننده احتمالی محسوب می‌شود [۲۸]. برای پیاده‌سازی این دسته‌بندی‌کننده از کلاس GaussianNB کتابخانه sklearn پایتون استفاده شده است.

برای نشان دادن اختلاف میان الگوی انتشار در حالت شایعه و غیر شایعه، دو مدل آبخاری مستقل و آستانه خطی [۲۳] که مدل‌هایی برای گسترش اطلاعات می‌باشند و مدل SIR [۲۶] که مدلی مبتنی بر اپیدمی برای تعریف چگونگی انتشار شایعات استفاده می‌شود، در شبکه باراباشی آلبرت پیاده‌سازی شده است. سپس زیر گراف انتشار در هر گام استخراج و نمودار توزیع فراوانی درجه آن در شکل (۱) نشان داده شده است.

شبکه باراباشی آلبرت [۲۷] یک شبکه مقیاس آزاد توانی است و همان‌گونه که در شکل مشخص است در گام‌های پایین در حالت انتشار شایعه، گراف انتشار نیز شکل توزیع درجه توانی را به خود گرفته است. درحالی‌که در حالات غیرشایعه در مدت طولانی‌تر این توزیع ایجاد می‌شود؛ بنابراین استفاده از ویژگی‌های مرتبط با توزیع درجه مناسب می‌باشد.

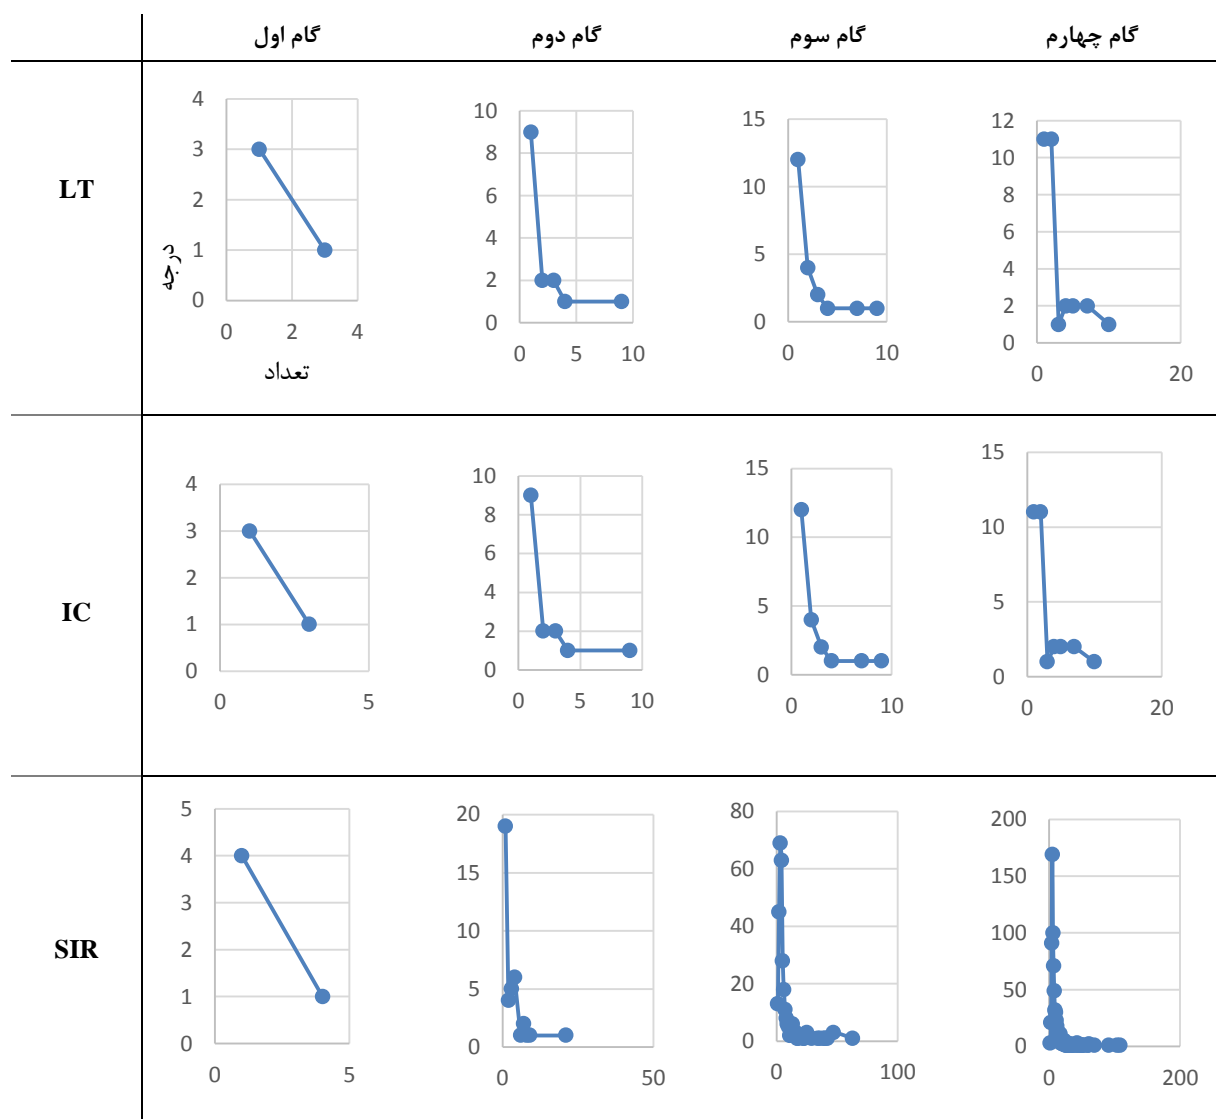
از آنجایی که فراوانی درجه رئوس ویژگی مهمی در بررسی مقایسه شبکه‌های پیچیده هست [۲۸]، در این پژوهش از این ویژگی به منظور بررسی و مقایسه گراف‌های انتشار استفاده شده است. به منظور رسیدن به این هدف ابتدا با توجه به پژوهش [۲۸] بردارهای ویژگی هر یک از گراف‌ها استخراج شده و سپس به دسته‌بندی‌کننده داده می‌شود. این ویژگی‌ها به صورت زیر (معادلات ۱-۸) محاسبه می‌شود که $D(v)$ درجه گره v و $P_G(d)$ احتمال این که درجه گره برابر با d باشد را نشان می‌دهد.

$Q(G)$ یک بردار هشت‌تایی مرتبط با ویژگی‌های فراوانی درجه گراف‌ها در هر گام انتشار است. در این پژوهش بردار ویژگی Q برای هر کدام محاسبه شده و به منظور تشخیص شایعه به دسته‌بندی‌کننده داده می‌شود.

به عنوان نمونه، یک گره تصادفی در شبکه باراباشی آلبرت انتخاب و انتشار را با مدل آستانه خطی انجام دادیم. گراف‌های انتشار در گام اول، دوم، سوم و چهارم در شکل (۲) مشخص است. برای گراف‌های انتشار در هر گام مقدار بردار Q نیز محاسبه شده است. گراف انتشار به همراه مقادیر بردار Q در چهار گام اول انتشار در شکل (۲) نشان داده شده است.

برای تشخیص الگوی انتشار، زیرگراف‌های انتشار در گام‌های سوم و چهارم به دست آمد. در مجموع سه دسته ویژگی تعریف می‌شود. دسته اول بردار هشت‌تایی گام سوم، دسته دوم بردار هشت‌تایی گام چهارم و دسته آخر بردار ۱۶ تایی گام سوم و چهارم است.

¹ Gaussian Naive Bayes



شکل (۱). مقایسه فراوانی درجه زیرگراف‌های انتشار در سه مدل SIR، IC و LT

قابل تفکیک باشند. سپس معادله خطی را می‌یابد که بیشترین فاصله را بین دو دسته ایجاد کند [۳۰]. برای پیاده‌سازی این دسته‌بندی‌کننده نیز از کلاس SVC کتابخانه sklearn پایتون استفاده شده است.

دسته‌بندی‌کننده آنالیز تشخیص خطی^۳ (LDA): این دسته‌بندی‌کننده یک روش آماری است که برای پیدا کردن ترکیب خطی که دو یا چند کلاس را از هم جدا می‌کند استفاده می‌شود [۳۱]. در این پژوهش از کلاس LinearDiscriminantAnalysis کتابخانه sklearn پایتون به‌منظور پیاده‌سازی این دسته‌بندی‌کننده استفاده شده است.

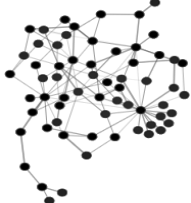
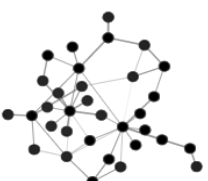
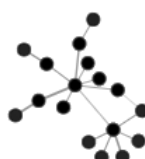

دسته‌بندی‌کننده جنگل تصادفی^۱ (RF): این دسته‌بندی‌کننده یک دسته‌بندی‌کننده ترکیبی مبتنی بر الگوریتم درخت تصمیم است و درخت‌های تصمیم مختلفی را با انتخاب زیرمجموعه‌های مختلف تولید می‌کند. هرکدام از این درخت‌ها یک حدس می‌زنند. سپس در دسته‌بندی‌کننده مقدار با بیشترین نظر برای این حدس‌ها انتخاب می‌شوند [۲۹]. به‌منظور پیاده‌سازی این دسته‌بندی‌کننده از کلاس RandomForestClassifier کتابخانه sklearn پایتون استفاده شده است.

دسته‌بندی‌کننده ماشین بردار پشتیبان^۲ (SVM): این دسته‌بندی‌کننده داده‌ها را با توجه به دسته‌های تعیین‌شده به یک فضای جدید برده طوری که آن‌ها به‌صورت خطی

^۳ Linear Discriminant Analysis

^۱ Random Forest
^۲ Support Vector Machine

شکل (۲). محاسبه مقادیر بردار هشت تایی Q برای زیرگراف انتشار در گام‌های اول تا چهارم

 <p>(د) زیر گراف انتشار پس از گام چهارم بردار Q: {0,0,0.539,0.253,0.0476,0.0634,0.0793,0.0158}</p>	 <p>(ج) زیر گراف انتشار پس از گام سوم بردار Q: {0,0,0.636,0,0.212,0.0303,0.0606,0.0606}</p>	 <p>(ب) زیر گراف انتشار پس از گام دوم بردار Q: {0,0,0.588,0,0.294,0,0,0.117}</p>	 <p>(الف) زیر گراف انتشار پس از گام اول بردار Q: {0,0,0.88,0,0,0,0.11}</p>
---	--	--	---

جدول (۱). ماتریس درهم‌ریختگی

		برچسب پیش‌بینی شده	
		مثبت	منفی
برچسب شناخته شده	مثبت	TP	FN
	منفی	FP	TN

- TP: پست منتشرشده شایعه است و روش به‌درستی آن را شایعه تشخیص داده است.
 - TN: پست منتشرشده شایعه نیست و روش به‌درستی شایعه نبودن آن را تشخیص داده است.
 - FP: پست منتشرشده شایعه نیست اما روش به‌اشتباه آن را شایعه تشخیص داده است.
 - FN: پست منتشرشده شایعه است اما به‌اشتباه تشخیص داده که شایعه نیست.
- با استفاده از داده‌های عددی در مورد پیش‌بینی‌های غلط و درست در ماتریس درهم‌ریختگی معیارهای دقت، صحت، فراخوانی و F1-score محاسبه می‌شود که چگونگی محاسبه در معادلات (۶-۹) آمده است.

$$\text{دقت} = \frac{TP+TN}{TP+TN+FN+FP} \quad (۶)$$

$$\text{صحت} = \frac{TP}{TP+FP} \quad (۷)$$

$$\text{فراخوانی} = \frac{TP}{TP+FN} \quad (۸)$$

$$\text{F1-score} = ۲ * \frac{\text{فراخوانی} * \text{صحت}}{\text{فراخوانی} + \text{صحت}} \quad (۹)$$

- دقت: نسبت پیش‌بینی‌های درست روش ارائه‌شده به همه پیش‌بینی‌ها را نشان می‌دهد.
- صحت: این معیار مشخص می‌کند چه تعداد از داده‌ها به‌درستی شایعه تشخیص داده شده‌اند. هرچقدر این معیار بیشتر باشد میزان پیش‌بینی درست شایعه بالاتر است.

هرکدام از دسته‌بندی‌کننده‌ها با ویژگی‌های موردنظر و مجموعه داده‌های موجود ارزیابی می‌شود که نتایج حاصل از آن‌ها در بخش بعد خواهد آمد.

۳-۴- انتخاب دسته‌بندی‌کننده

به‌منظور انتخاب دسته‌بندی‌کننده مناسب، چهار دسته‌بندی‌کننده اصلی که بیشتر در حوزه تشخیص شایعات استفاده می‌شدند، تعیین شد. هرکدام از دسته‌بندی‌کننده‌ها با سه ویژگی اصلی، بر روی داده‌های آزمایشی به‌دست‌آمده از شبکه باراباشی آلبرت، واتزاشتروگاتز و شبکه واقعی و داده‌های واقعی موردبررسی قرار می‌گیرد. در ادامه توضیح مختصری راجع به این شبکه‌ها داده خواهد شد.

- شبکه باراباشی آلبرت: از آنجایی که فرض این است که شبکه‌های اجتماعی مقیاس آزاد هستند این نوع شبکه‌ها نیز نزدیک‌ترین شبکه‌ها به شبکه اجتماعی هستند که شبکه‌های مقیاس آزاد تصادفی تولید می‌کنند [۲۷].
 - شبکه واتز - اشتروگاتز: این مدل نیز گراف تصادفی با ویژگی‌های جهان کوچک را تولید می‌کند [۳۲].
 - شبکه واقعی: شبکه به‌دست‌آمده از توپیتز با توجه به مجموعه داده PHEME که شامل ۱۷۴۲۶ گره و ۳۳۵۹۸ یال است [۳۳].
- با توجه به روش ارزیابی که در ادامه می‌آید و نتایج حاصل از این ارزیابی، دسته‌بندی‌کننده‌ای که نتیجه‌ای بهتری را دارد، انتخاب می‌شود.

۳-۵- روش ارزیابی

یکی از روش‌هایی که برای اندازه‌گیری میزان موفقیت الگوریتم‌های یادگیری ماشین استفاده می‌شود، ماتریس‌های درهم‌ریختگی^۱ است که در جدول (۱) نشان داده شده است.

^۱ Confusion Matrix

با یکی از مدل‌های انتشار آبخاری مستقل، آستانه خطی و مدل اپیدمی SIR (با مقدار $0 < \mu < 0.4$ و $0 < \beta < 0.2$) انتشار انجام می‌شود. سپس گراف انتشار برای هر یک از این مدل‌ها به دست می‌آید و بردار ویژگی $Q(G)$ برای گام سوم و گام چهارم محاسبه می‌شود.

در نهایت این بردار ویژگی به دسته‌بندی‌کننده برای تشخیص شایعه داده می‌شود. نمونه‌ای از داده‌های این آزمایش‌ها در جدول (۳) آورده شده است.

از آنجایی که SIR مدل مربوط به انتشار شایعه است، برچسب ۱ دارد و دو مدل دیگر مربوط به انتشار غیرشایعه هستند که برچسب صفر دارند.

۴-۴- نتایج

در این قسمت به بررسی نتایج حاصل از پیاده‌سازی این روش و ارزیابی آن پرداخته خواهد شد.

۴-۴-۱- نتایج حاصل از بررسی فراوانی درجه زیرگراف انتشار در شبکه باراباشی آلبرت و واتز اشتروگاتز

نمودار توزیع فراوانی درجه گراف‌های انتشار در هر گام برای مدل انتشار آبخاری مستقل، آستانه خطی و SIR مورد بررسی قرار گرفته شده است. شکل (۳)، شکل (۴) و شکل (۵) به ترتیب چگونگی رشد گراف انتشار را در شبکه باراباشی آلبرت هنگامی که مدل انتشار LT، IC و SIR است نشان می‌دهد. شکل (۶)، شکل (۷) و شکل (۸) نیز این چگونگی رشد گراف انتشار را در شبکه واتز اشتروگاتز به نمایش گذاشته است.

همان‌گونه که در نمودارها مشخص است، هنگامی که شایعه منتشر می‌شود، زیرگراف انتشار با سرعت بیشتری شبیه گراف اصلی می‌شود و توزیع درجه آن سریع‌تر مانند توزیع درجه گراف اصلی می‌شود. تعداد گام‌ها تا انتشار کامل نیز به طرز واضحی کاهش می‌یابد.

جدول (۲). اطلاعات مربوط به مجموعه داده واقعی PHEME [۳۳]

رویداد مربوطه	غیرشایعات	شایعات
#charliehebdo	۱۶۲۱	۴۵۸
#ferguson	۸۵۹	۲۸۴
#germanwingscrash	۲۳۱	۲۳۸
#ottawashooting	۴۲۰	۴۷۰
#sydneyseige	۶۹۹	۵۲۲

فراخوانی: این معیار نسبت پیش‌بینی‌های درست شایعه را به همه شایعات مشخص می‌کند.

F1-score: به‌منظور در نظر گرفتن صحت و فراخوانی به‌صورت هم‌زمان از این معیار استفاده می‌کنند و حاصل میانگین هارمونیک این دو معیار است.

پس از آن به‌منظور ارزیابی روش ارائه شده، گراف مرتبط با هر پست شایعه و غیرشایعه تولید شد، سپس بردار ویژگی‌های مرتبط با هر کدام در گام‌های سوم و چهارم محاسبه شد. در نهایت هر کدام از آن‌ها به‌منظور تشخیص شایعه بودن یا نبودن به دسته‌بندی‌کننده‌های طراحی شده وارد و معیارها برای آن‌ها محاسبه گردید. از اعتبارسنجی متقابل پنج‌تایی نیز به‌منظور ارزیابی دسته‌بندی‌کننده‌ها استفاده شد.

۴- پیاده‌سازی و ارزیابی

در این بخش به توضیح چگونگی پیاده‌سازی آزمایش‌ها و نتایج آن پرداخته خواهد شد. روش موردنظر روی مجموعه‌ای از داده‌های شبیه‌سازی شده و بررسی داده‌های واقعی ارزیابی می‌شود.

۴-۱- مشخصات دادگان شبیه‌سازی شده

به‌منظور بررسی روش موردنظر در توپولوژی‌های مختلف، دو نوع شبکه معروف واتز اشتروگاتز، باراباشی آلبرت انتخاب شد. به‌منظور بررسی ابعاد مختلف نیز، از هر شبکه به تعداد ۱۰۰۰، ۲۵۰۰ و ۵۰۰۰ گره در نظر گرفته شده است.

۴-۲- مشخصات دادگان واقعی

یکی از معروف‌ترین مجموعه داده‌های مربوط به تشخیص شایعات، مجموعه داده PHEME است [۳۳]. این مجموعه داده شامل پنج رویداد می‌باشد. که در آن پست‌های شایعات و غیر شایعات مشخص شده است. تعداد آن‌ها در جدول (۲) آمده است.

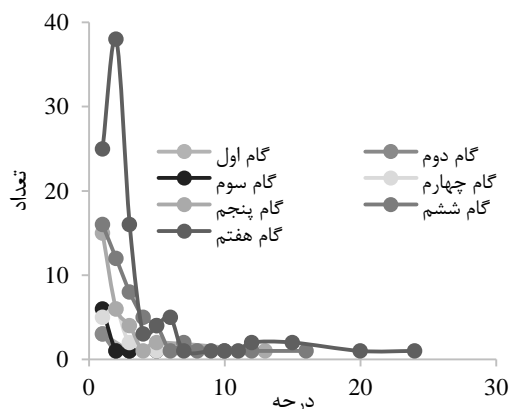
با توجه به این مجموعه داده و روابط بین کاربران در این مجموعه داده، یک شبکه واقعی ساخته شده است. علاوه بر آن با توجه به اطلاعات موجود برای هر پست، گراف انتشار هر پست در شبکه قابل استخراج است. گراف انتشار مربوط به هر پست تشکیل شده و سپس بردارهای Q مربوط به انتشار به دسته‌بندی‌کننده داده می‌شود. نتایج مربوط به ارزیابی در قسمت بعد بیان و با روش‌های موجود مقایسه خواهد شد.

۴-۳- مشخصات آزمایش‌های طراحی شده


به‌منظور بررسی حالات مختلف حدود ۱۰۰ شبکه با پارامترهای ذکر شده با استفاده از کتابخانه Networkx پایتون تولید شد. سپس نود شروع به‌صورت تصادفی انتخاب می‌شود و

آزمایشات بر روی دادگان شبیه‌سازی شده، در شبکه‌های باراباشی آلبرت، واتز اشتروگاتز و شبکه واقعی ارزیابی شده است.


در مجموع سه دسته ویژگی تعریف می‌شود. دسته اول در شبکه‌های باراباشی آلبرت، واتز اشتروگاتز و شبکه واقعی ارزیابی شده است. بردار هشت‌تایی گام سوم، دسته دوم بردار هشت‌تایی گام چهارم و دسته آخر بردار شانزده‌تایی گام سوم و چهارم است. دسته‌بندی‌کننده‌ها برای سه دسته ویژگی، یاد داده شده است.



شکل (۳). نمودار توزیع فراوانی درجه در حالتی که شبکه باراباشی آلبرت و مدل انتشار LT است. (TNS=17)



شکل (۴). نمودار توزیع فراوانی درجه در حالتی که شبکه باراباشی آلبرت و مدل انتشار IC است. (TNS=23)



شکل (۵). نمودار توزیع فراوانی درجه در حالتی که شبکه باراباشی آلبرت و مدل انتشار SIR است. (TNS=5)

پس از بررسی فراوانی درجه در گراف انتشار در سه مدل آبخاری مستقل، آستانه خطی و SIR مشخص شد که هنگامی که در حدود نصف گام تا انتشار کامل طی شود، توزیع درجه در زیرگراف انتشار به صورت شبکه‌ای می‌شود که شایعه در آن منتشر شده است.

به‌عنوان مثال در شکل (۳)، شکل (۴) و شکل (۵) که شبکه باراباشی آلبرت است و توزیع درجه به صورت توانی است، در حالتی که شایعه منتشر می‌شود، پنج گام طول می‌کشد که کل شبکه شایعه را شنیده باشند و انتشار کامل شده باشد که TNS یعنی تعداد گام تا انتشار کامل (Total Number of Steps) برابر ۵ است، در این حالت از گام سوم توزیع درجه گراف انتشار به صورت توانی می‌شود درحالی که در مدل‌های LT و IC، به ترتیب ۱۷ و ۲۳ گام انتشار کامل طول می‌کشد و هنگامی که به ترتیب در گام ۹ و ۱۲ باشد، توزیع گراف انتشار به شکل توانی می‌شود.

جدول (۳). نمونه به دست آمده از اجرای آزمایشات

نوع شبکه	BA	BA	BA
تعداد گره	۱۰۰۰	۱۰۰۰	۱۰۰۰
مدل انتشار	SIR	IC	LT
برچسب	۱	۰	۰
گام Q(1)	۱	۰/۲۵	۰
گام Q(2)	۰	۰	۰
گام Q(3)	۰	۰/۲۵	۰/۵
گام Q(4)	۰/۷۳۹	۰	۰
گام Q(5)	۰/۰۸۶۹	۰/۵	۰/۲
گام Q(6)	۰/۰۸۶۹	۰	۰/۱
گام Q(7)	۰/۰۷۲۴	۰	۰
گام Q(8)	۰/۰۲۴۸	۰	۰/۲

حال اگر شایعه در یک شبکه با توزیع توانی منتشر شود، در گام‌های پایین توزیع درجه توانی می‌شود؛ بنابراین می‌توان در گام‌های ابتدایی اگر فراوانی درجه توانی شد، شایعه را تشخیص داد. در شبکه واتز اشتروگاتز نیز که توزیع نرمال است، همین قاعده وجود دارد و توزیع درجه گراف هنگامی که شایعه باشد، سریع‌تر مانند شبکه اصلی می‌شود.

۲-۳-۴- نتایج حاصل از دادگان آزمایشی

در این پژوهش برای تشخیص تفاوت‌های توزیع درجه مدل‌ها از دسته‌بندی‌کننده‌های GNB، RF، SVM و LDA استفاده شده است. این آزمایش‌ها بر روی دادگان شبیه‌سازی شده، این


جدول (۴). نتایج به دست آمده از اعمال دسته‌بندی کننده‌های مختلف بر روی مجموعه داده به دست آمده از شبکه باراباشی آلبرت

دسته‌بندی کننده	ویژگی‌ها	صحت	دقت	فراخوازی	F1-score
gnb	F2	۶۳/۵۶	۷۳/۰۱	۸۹/۷	۷۴/۴۱
		۶۰/۰۴	۷۱/۴۴	۹۲/۳	۷۲/۷۸۲
	F1+F2	۷۴/۴۴	۷۹/۷۳	۷۵/۰۲	۷۴/۷۳
Lda	F1	۶۵/۳۸	۶۹/۸۴	۷۸/۶۸	۷۱/۴۲
	F2	۶۴	۶۹/۹۸	۶۷/۵۹	۶۵/۷۵
	F1+F2	۶۶/۵۳	۷۰/۳۱	۷۱/۰۶	۶۸/۷۰
RF	F1	۶۴/۹۲	۷۳/۷۴	۶۴/۹۲	۸۱/۱۵
	F2	۷۰	۷۶/۷۰	۷۰	۷۳/۴۵
	F1+F2	۷۸/۵۷	۸۱/۴۰۳	۷۸/۴۰	۷۴/۳۵
SVM	F1	۶۹/۶۶	۵۹	۶۹/۶۶	۶۹/۶۶
	F2	۷۲	۷۰/۴۷	۷۲	۶۸/۵
	F1+F2	۷۸	۷۰	۷۸	۷۰/۷۱


۲-۳-۴- نتایج حاصل از دادگان واقعی

روش پیشنهادی این پژوهش با روش‌های مبنایی موجود مقایسه شده، بدین منظور نتایج از مقاله [۲۵] به دست آمده است و سعی شده است که شرایط ارزیابی نیز مانند شرایط مطرح شده در مقاله و مجموعه داده PHEME باشد.

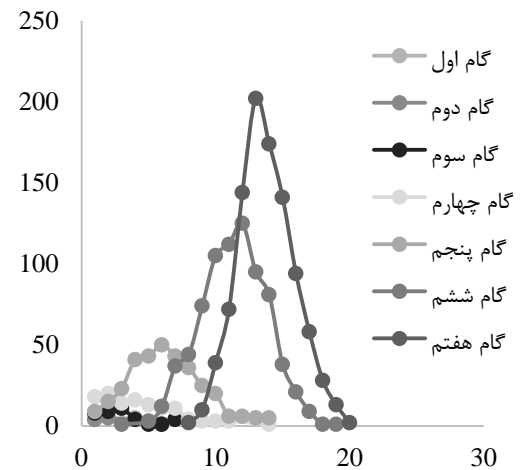
این مقالات از روش‌های مختلف استفاده می‌کنند که شامل یادگیری عمیق و روش‌های استخراج دستی ویژگی‌ها می‌شود. روش ارائه شده با مقاله [۲۵] نیز که یک روش مبتنی بر یادگیری عمیق نیز می‌باشد مقایسه شده است و نتایج حاصل از آن درآمده است.



شکل (۶). نمودار توزیع فراوانی درجه در حالتی که شبکه واتز اشتروگاتز و مدل انتشار LT است. (TNS=14)



شکل (۷). نمودار توزیع فراوانی درجه در حالتی که شبکه باراباشی آلبرت و مدل انتشار IC است. (TNS=23)



شکل (۸). نمودار توزیع فراوانی درجه در حالتی که شبکه واتز اشتروگاتز و مدل انتشار SIR است. (TNS=7)

نتایج حاصل از اجرای این روش بر روی دادگان آزمایشی حاصل از شبکه باراباشی آلبرت، شبکه واتز اشتروگاتز و شبکه واقعی به ترتیب در جدول (۴)، جدول (۵) و جدول (۶) آمده است.

جدول (۵). نتایج به دست آمده از اعمال دسته بندی کننده های مختلف بر روی مجموعه داده به دست آمده از شبکه واتز اشتروگاتز

دسته بندی کننده	ویژگی ها	صحت	دقت	فراخوانی	F1-score
gnb	F2	۶۳/۵۶	۷۳/۰۱	۸۹/۷	۷۴/۴۱
		۶۰/۰۴	۷۱/۴۴	۹۲/۳	۷۲/۷۸۲
	F1+F2	۷۴/۴۴	۷۹/۷۳	۷۵/۰۲	۷۴/۷۳
Lda	F1	۶۵/۳۸	۶۹/۸۴	۷۸/۶۸	۷۱/۴۲
	F2	۶۴	۶۹/۹۸	۶۷/۵۹	۶۵/۷۵
	F1+F2	۶۶/۵۳	۷۰/۳۱	۷۱/۰۶	۶۸/۷۰
RF	F1	۶۴/۹۲	۷۳/۷۴	۶۴/۹۲	۸۱/۱۵
	F2	۷۰	۷۶/۷۰	۷۰	۷۳/۴۵
	F1+F2	۷۸/۵۷	۸۱/۴۰۳	۷۸/۴۰	۷۴/۳۵
	F1	۶۹/۶۶	۵۹	۶۹/۶۶	۶۹/۶۶
SVM	F2	۷۲	۷۰/۴۷	۷۲	۶۸/۵
	F1+F2	۷۸	۷۰	۷۸	۷۰/۷۱

همان گونه که از نتایج مشخص است بهترین نتیجه مربوط به استفاده از دسته بندی کننده RF و ویژگی های بردار Q مربوط به گام سوم و چهارم است.

۵-۴- تحلیل نتایج

از نتایج به دست آمده بر روی شبکه های مختلف مشخص می شود که امکان تشخیص بر اساس گراف انتشار در چهار گام اول وجود دارد و از بین دسته بندی کننده های موجود، RF به دلیل اینکه ترکیب چند درخت تصمیم مختلف است و برای داده های نامتعادل که شایعات نیز از این دسته هستند، مناسب تر است، نتایج بهتری دارد. این دسته بندی کننده به دلیل خاصیت ترکیبی که دارد، با داده های نویزی رفتار بهتری دارد.

- SVM[34]: یک دسته بندی کننده SVM برای تشخیص شایعات استفاده کرده است، ویژگی های استخراج شده شامل ویژگی های مربوط به محتوای پست، کاربر، موضوع بحث و الگوی انتشار می باشد.

- DTR[35]: یک روش مبتنی بر جست و جوی عبارات می باشد و پست های مشابه را با یکدیگر طبقه بندی می کند، سپس از درخت تصمیم برای رتبه بندی احتمال شایعه بودن استفاده می کند.

- RFC-PR[36]: این مقاله پست ها و پاسخ هایشان را به عنوان گراف دسته بندی می کند. این گراف ها با استفاده از ویژگی های گره و ساختارشان در یک بردار تعبیه می شوند. سپس از RF برای دسته بندی بردارها استفاده می کند.

- RvNN[37]: یک مدل درختی بالا به پایین و پایین به بالا مبتنی بر شبکه های عصبی بازگشتی ارائه داده است.

- SSGE[25]: از یک شبکه گراف کانولوشنی برای یادگیری بردارها استفاده می کند. بهترین نتیجه این مقاله با روش ارائه شده مقایسه شده است.

به منظور بررسی این روش بر روی داده های واقعی، گراف های انتشار پست های مربوط به مجموعه داده واقعی PHEME استخراج شده و به دسته بندی کننده های طراحی شده، به عنوان داده تست داده می شود که بهترین نتایج در مقایسه با روش های مبنایی در جدول (۷) آورده شده است.

- PM(Lda(F2)): استفاده از روش ارائه شده با دسته بندی کننده های F2 (بردار Q مربوط به گام سوم) و LDA.

- PM(Lda(F1+F2)): استفاده از روش ارائه شده با دسته بندی کننده های F1+F2 (بردار Q مربوط به گام سوم و چهارم) و LDA.

- PM(RF(F2)): استفاده از روش ارائه شده با دسته بندی کننده های F2 (بردار Q مربوط به گام سوم و چهارم) و RF.

- PM(RF(F1+F2)): استفاده از روش ارائه شده با دسته بندی کننده های F1+F2 (بردار Q مربوط به گام سوم و چهارم) و RF.

روش ارائه شده در این مقاله از لحاظ دقت نتیجه‌ای مشابه روش SGEE دارد اما از آنجایی که در مسئله تشخیص شایعات به دلیل نامتعادل بودن شایعات به نسبت غیر شایعات، (شایعات تعداد کمتری دارد) معیار دقت به‌تنهایی قادر به نشان دادن کارایی مدل نیست، نیاز است معیار جزئی‌تری نیز مورد بررسی قرار گیرد. علاوه بر آن به دلیل اینکه تشخیص نادرست شایعات و غیر شایعات نیز در مدل‌های تشخیص شایعه اهمیت زیادی دارد و معیار F1-score به این موضوع توجه می‌کند، این معیار نیز مورد مقایسه قرار گرفته است که مشخص می‌کند روش ارائه شده با استفاده از RF بهترین نتیجه را از لحاظ F1-Score دارد. علاوه بر آن روش SGEE مبتنی بر یادگیری عمیق است که زمان آموزش طولانی‌تری نسبت به روش ارائه شده نیاز دارد. در صورتی که RF زمان آموزش کمتری نیازمند است و دقتی در حدود روش SGEE با F1-score بالاتر دارد که بهینه‌تر است. روش ارائه شده از لحاظ زمانی نیز در نهایت بعد از گذشت ۴ گام قادر به تشخیص شایعه است.

۴- نتیجه‌گیری

در این پژوهش روشی مبتنی بر توزیع درجه گراف انتشار برای تشخیص شایعات ارائه شد که پس از چهار گام از شروع انتشار، قادر به تشخیص آن است. بدین منظور دسته‌بندی‌کننده‌های مختلفی مورد ارزیابی قرار گرفت که از بین آن‌ها RF بهترین نتیجه را داشت. در این پژوهش برخلاف پژوهش‌های پیشین نیاز به تحلیل محتوا و بررسی پروفایل کاربر وجود ندارد و تنها با استفاده از توزیع درجه گراف انتشار امکان تشخیص شایعه فراهم می‌شود، در آینده به بررسی سایر ویژگی‌های گراف انتشار و تأثیر آن بر بهبود عملکرد روش ارائه شده پرداخته خواهد شد.

۵- مراجع

- [1] K. Kumar & G. Geethakumari, "Analysis of Semantic Attacks in Online Social Networks," in Recent Trends in Computer Networks and Distributed Systems Security, vol. 420, pp. 45-56, 2014.
- [2] G. W. Allport & L. Postman, "The psychology of rumor," Journal of Clinical Psychology, vol. 3, pp. 402-402, 1947.
- [3] B. Guerin & Y. Miyazaki, "Analyzing rumors, gossip, and urban legends through their conversational properties," The Psychological Record, vol. 56, pp. 2-10, 2010.
- [4] J. Ma, W. Gao, & K.F. Wong, "Detect Rumors in Microblog Posts Using Propagation Structure via Kernel Learning," in Association for Computational Linguistics, 2017.

از آنجایی که بردار ویژگی‌های Q خود یک بردار هشت‌تایی است که ممکن است همه آن‌ها تأثیر یکسانی نداشته باشند، الگوریتم RF قادر است با استفاده از آن‌ها درخت‌های تصمیم متفاوتی ساخته و بر اساس بهترینشان تصمیم‌گیری را انجام دهد.

جدول (۶). نتایج به‌دست آمده از اعمال دسته‌بندی‌کننده‌های مختلف بر روی مجموعه داده به‌دست آمده از شبکه واقعی

دسته‌بندی کننده	ویژگی‌ها	صحت	دقت	فراخوانی	F1-score
gnb	F1	۷۶/۸	۷۵/۵۵	۹۷	۷۶/۸
	F2	۶۰	۷۱/۰۱	۸۴/۶	۷۰/۲۴
	F1+F2	۶۰	۶۷/۳۳	۳۸/۳۹	۵۰/۶۶
lda	F1	۶۳/۶	۷۶/۶۶	۷۱/۵۵	۶۸/۳۳
	F2	۵۴/۲۶	۷۰/۷۶	۶۷/۵۱	۶۵/۷۱
	F1+F2	۶۲/۸۳	۶۹/۳	۷۲/۶۳	۶۹/۴۵
RF	F1	۷۷/۳۸	۷۷/۸۶	۷۲/۹۹	۶۸/۷۲
	F2	۷۸/۸۰	۷۹/۶۷	۷۰/۷۹	۷۴/۴۸
	F1+F2	۸۲/۶۶	۷۹/۴۵	۷۳/۸۱	۷۷/۹۹
SVM	F1	۷۲/۲۲	۵۶/۶۶	۳۰/۹۴	۴۳/۳۳
	F2	۰/۶۸	۰/۶۷۳	۰/۶۲۸	۰/۶۵۳
	F1+F2	۵۶/۶۶	۷۶/۴۴	۵۶/۶۶	۵۱/۴۲

در بین روش‌هایی که مورد مقایسه قرار گرفت، ابتدا روش SGEE و سپس RvNn از همه بهتر عمل می‌کند که RvNN به دلیل استفاده از ساختار بازگشتی درختی و تجمیع اطلاعات مربوط به توییت‌ها نتیجه بهتری دارد و روش SGEE به دلیل اینکه برای هر گراف انتشار ویژگی‌های دیگر پست را نیز قبل از دسته‌بندی ترکیب می‌کند از بقیه نتیجه بهتری دارد.

جدول (۷). مقایسه روش ارائه شده با روش‌های موجود

روش	فراخوانی	F1-score	دقت	صحت
SVMC	۰/۱۵۴	۰/۲۴۳	۰/۶۳۹	۰/۵۶۳
DTR	۰/۴۲۳	۰/۴۱۵	۰/۵۵۳	۰/۴۰۷
RFC-PR	۰/۶۹۸	۰/۷۴۱	۰/۸۱۷	۰/۷۸۹
RvNN	۰/۷۵۸	۰/۷۶۵	۰/۸۲۵	۰/۷۷۲
SGE-mean	۰/۸۱۹	۰/۷۹۵	۰/۸۴۲	۰/۷۷۲
PM(lda(F2))	۰/۸۳۱	۰/۸۶۲	۰/۸۱۸	۰/۸۹۵
PM(lda(F1+F2))	۰/۷۵۴	۰/۷۹۲	۰/۷۳۷	۰/۸۳۴
PM(RF(F2))	۰/۸۰۷	۰/۷۶۴	۰/۸۰۲	۰/۷۲۵
PM(RF(F1+F2))	۰/۹۰۱	۰/۸۷۸	۰/۸۴۱	۰/۸۵۶

- networks," *Physica A: Statistical Mechanics and its Applications*, vol. 394, pp. 99-109, 2014.
- [19] A. I. E. Hosni, K. Li, & S. Ahmad, "Minimizing rumor influence in multiplex online social networks based on human individual and social behaviors," *Information Sciences*, vol. 512, pp. 1458-1480, 2020.
- [20] L. Fan, Z. Lu, W. Wu, B. Thuraisingham, H. Ma, & Y. Bi, "Least cost rumor blocking in social networks," in *2013 IEEE 33rd International Conference on Distributed Computing Systems*, 2013.
- [21] Y. Liu & S. Xu, "Detecting rumors through modeling information propagation networks in a social media environment," *IEEE Transaction on computational social systems*, vol. 3, pp. 46-62, 2016.
- [22] C. Budak, D. Agrawal, & A. El Abbad "Limiting the spread of misinformation in social networks," in *Proceedings of the 20th international conference on World wide web*, 2011.
- [23] M. Jalili & M. Perc, "Information cascades in complex networks," *Journal of Complex Networks*, vol. 5, pp. 665-693, 2017.
- [24] A. Ye, L. Wang, R. Wang, W. Wang, J. Ke, & D. Wang, "An End-to-End Rumor Detection Model Based on Feature Aggregation," *Complexity*, vol. 2, pp. 1-16, 2021.
- [25] D. T. Vu & J. J. Jung, "Rumor Detection by Propagation Embedding Based on Graph Convolutional Network," *International Journal of Computational Intelligence Systems*, vol. 14, pp. 1053-1065, 2021.
- [26] . Zhao, H. Cui, X. Qiu, X. Wang, & J. Wang, "SIR rumor spreading model in the new media age," *Physica A: Statistical Mechanics and its Applications*, vol. 3, pp. 995-1003, 2013.
- [27] A.-L. Barabási & R. Albert, "Emergence of scaling in random networks," *science*, vol. 286, pp. 509-512, 1999.
- [28] S. Aliakbary, J. Habibi, & A. Movaghar, "Feature extraction from degree distribution for comparison and analysis of complex networks," *The Computer Journal*, vol. 58, pp. 2079-2091, 2015.
- [29] S. Mughdha, M. Kuddus, L. Salsabil, A. Anika & S. shatabda, "A Gaussian Naive Bayesian Classifier for Fake News Detection in Bengali," in *Emerging Technologies in Data Mining and Information Security*, pp. 283-291, 2021.
- [30] C. Adele, D.C. Richard, & J. R. Stevens, "Random forests," in *Ensemble machine learning*, pp. 157-175, 2012.
- [31] V. Yadegari, & A. R. Matinfar, "Detect Web Denial of Service Attacks Using Entropy and Support Vector Machine Algorithm," *Journal of Electronical & Cyber Defence*, vol. 6, pp. 79-89, 2019. (In Persian)
- [32] R. A. Fisher, "The use of multiple measurements in taxonomic problems," *Annals of eugenics*, vol. 7, pp. 179-188, 1936.
- [5] N. DiFonzo & P. Bordia, "Rumor, Gossip and Urban Legends," *Diogenes*, vol. 54, pp. 19-35, 2007.
- [6] K. Kumar & G. Geethakumari, "Detecting misinformation in online social networks using cognitive psychology", *Human-centric Computing and Information Sciences*, vol. 4, pp. 1-22, 2014.
- [7] X. Dong, Y. Lian, Y. Chi, X. Tang, & Y. Liu, "A two-step rumor detection model based on the supernet theory about Weibo," *The Journal of Supercomputing*, pp. 1-25, 2021.
- [8] B. Galitsky, "Detecting Rumor and Disinformation by Web Mining," *2015 AAAI Spring Symposium*, 2015.
- [9] S. Vosoughi, "Automatic Detection and Verification of Rumors on Twitter," PhD Thesis, the Program in Media Arts and Sciences In Massachusetts Institute of Technology, 2014.
- [10] E. L. Kochkina, M. Liakata and A. Zubiaga, "All-in-one: Multi-task Learning for Rumour Verificatio," in *Proceedings of the 27th International Conference on Computational Linguistics*, 2018.
- [11] A. Kumar, M. Bhatia, & S. R. Sangwan, "Rumour detection using deep learning and filter-wrapper feature selection in benchmark twitter dataset," *Multimedia Tools and Applications*, pp. 1-18, 2021.
- [12] M. Z. Asghar, A. Habib, A. Habib, A. Khan, R. Ali, & A. Khattak, "Exploring deep neural networks for rumor detection," *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, pp. 4315-4333, 2021.
- [13] Y. Peng & J. Wang, "Rumor Detection Based on Attention CNN and Time Series of Context Information," *Future Internet*, vol. 13, p. 267, 2021.
- [14] S. S. Natali Ruchansky & Yan Liu, "CSI: A Hybrid Deep Model for Fake News Detection," *Proceedings of the 2017 {ACM} on Conference on Information and Knowledge Management*, 2017.
- [15] Y. Zhou, C. Wu, Q. Zhu, Y. Xiang, & S. W. Loke, "Rumor Source Detection in Networks Based on the SEIR Model," *IEEE access*, vol. 7, pp. 45240-45258, 2019.
- [16] F.Zarifpour, M.Mojarad, & H. Arfaeinia, "Analysis of Rumor Spreading in Social Networks using Combination of SIR, SIHR and Autoencoder Models," *IJSRNSC*, vol. 8, pp. 1-6, 2020.
- [17] Y. Hu, Q. Pan, W. Hou, & M. He, "Rumor spreading model with the different attitudes towards rumors," *Physica A: Statistical Mechanics and its Applications*, vol. 502, pp. 331-344, 2018.
- [18] S. Han, F. Zhuang, Q. He, Z. Shi, & X. Ao, "Energy model for rumor propagation on social

- [37] Dang-Thinh Vu & J. J. Jung, "Detecting Emerging Rumors by Embedding Propagation Graphs," in *Information Retrieval Technology*, pp. 173-184, 2019.
- [38] J. Ma, W. Gao, & K.-F. Wong, "Rumor detection on Twitter with tree-structured recursive neural networks," in *56th Annual Meeting of the Association for Computational Linguistics (ACL 2018)*, pp. 1980-1989, 2018.
- [33] D. J. Watts & S. H. Strogatz, "Collective dynamics of 'small-world' networks," *nature*, vol. 393, pp. 440-442, 1998.
- [34] A. W. S. H. Zubiaga, Geraldine; Liakata, Maria; Procter, Rob, "PHEME dataset of Rumours and nonrumours. figshare. Dataset", figshare, 2016.
- [35] C.Castillo, M. Mendoza, & B. Poblete, "Information Credibility on Twitter," in *Proceedings of the 20th international conference on World wide web*, 2011.
- [36] Z. Zhao, P. Resnick, & Q. Mei, "Enquiring Minds: Early Detection of Rumors in Social Media from Enquiry Posts," in *Proceedings of the 24th international conference on world wide web*, 2015.