



Spring 2021, 2 (1), 1-9

DOR: 20.1001.1.27832570.1399.1.1.6.0

Received: 3 Jan 2021

Accepted: 20 Feb 2021

Comparative Analysis of Graphical Structural Metrics for Identifying Anomalies in Online Social Networks

Mojtaba Aajami^{1*}, Naser Asgari²

1. Assistant professor, Faculty of Electrical and Computer Engineering, Zanzan Branch, Islamic Azad University, Zanzan, Iran. (Corresponding Author) ajajami@iauz.ac.ir

2. MSc Student, Faculty of Electrical and Computer Engineering, Zanzan Branch, Islamic Azad University, Zanzan, Iran. asgari.naser@gmail.com

Abstract

Introduction: Social networks are exposed to a variety of security problems due to their wide use and popularity. Therefore, identifying unusual activities in social networks is of paramount importance as it helps to obtain significant information about the behavior of unusual users and identify them. One of the important aspects of social network analysis is to check the presence of anomalies. Anomalies in the field of social networks imply irregular and often illegal behavior. A host of methods have been proposed to detect different kinds of anomalies in social networks. According to the employed approach, these methods can be classified into three categories, namely, clustering-based, based on network structure-based, and signal processing-based. In this paper, we extend the graph structure-based approach by introducing and analyzing important graph metrics to detect abnormal activities. Theoretical and experimental evaluation using several large data sets demonstrate that the relationship between the interface node and the number of edges helps to correctly detect and rank the maximum number of anomalies.

Method: The proposed method is a combination of graphical and statistical theory. First, various metrics and graph structures are calculated, and then statistical methods are used to identify and analyze unusual structures (stars and clusters).

Results: Statistical and visual analysis shows that the area covered by the curve is maximum for the interface (B) compared to the number of edges (E). The results show that the proxy is a scale that can correctly detect many abnormalities. It can also be said that the relationship between the (B) and the (E) helps to predict most anomalies.

Discussion: In this research, a structure-based method was presented by using graph criteria to predict abnormalities. The curve fitting method based on the graph structure was extended to detect anomalies using the combination of new graph criteria. It was observed that the relationship between the interface and the edges helped to predict a large number of anomalies that were either misclassified or missed by the Oddball method and the ABC relationship to E. The abnormality scores assigned to the nodes help predict the degree of anomalies and rank the nodes according to their irrational behavior.

Keywords: Anomaly, Betweenness Centrality, Brokerage nodes, Clique, Social networks, Star network.

تجزیه و تحلیل تطبیقی معیارهای ساختاری گرافیکی برای شناسایی ناهنجاری‌ها در شبکه‌های اجتماعی آنلاین

سال دوم، بهار ۱۴۰۰
شماره اول، صص: ۱ - ۹

تاریخ دریافت: ۱۳۹۹/۱۰/۱۳
تاریخ پذیرش: ۱۳۹۹/۱۲/۰۲

مجتبی اعجمی^{*}، ناصر عسگری^۲

۱. استادیار، دانشکده مهندسی برق و کامپیوتر، واحد زنجان، دانشگاه آزاد اسلامی، زنجان، ایران. (نویسنده مسئول) aajami@iauz.ac.ir
۲. کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر، واحد زنجان، دانشگاه آزاد اسلامی، زنجان، ایران. asgari.naser@gmail.com

چکیده: شبکه‌های اجتماعی به دلیل استفاده وسیع و محبوبیت میان کاربران، با مشکلات امنیتی بسیاری مواجهند. بنابراین، شناسایی فعالیت‌های غیرعادی در شبکه‌های اجتماعی، به این دلیل که کمک می‌کند تا اطلاعات مهم و قابل توجهی در مورد رفتار کاربران غیرعادی به دست آورده و آن‌ها را شناسایی کنیم؛ مورد نیاز است. به منظور تشخیص ناهنجاری‌ها در شبکه‌های اجتماعی، محققان عمدتاً به رویکردهای مبتنی بر رفتار و ساختار متکی هستند. ما با استفاده از معرفی و تجزیه و تحلیل معیارهای مهم گراف برای تشخیص فعالیت‌های غیرعادی، رویکرد مبتنی بر ساختار گراف را گسترش می‌دهیم. مقایسه و اثربخشی اقدامات بر اساس سنجش‌های آماری مانند دقت، بازخوانی و F-Score و همچنین بر اساس نمرات غیرعادی محاسبه و ارائه شده است. ارزیابی نظری و تجربی روی چند مجموعه داده بزرگ نشان می‌دهد که رابطه بین گره واسط و تعداد لبه‌ها برای تشخیص و رتبه‌بندی حداکثری تعداد ناهنجاری‌ها به درستی کمک می‌کند.

واژه‌های کلیدی: ناهنجاری، مرکزیت بینابینی، گره واسط، دسته‌ها، شبکه‌های اجتماعی اینترنتی، شبکه‌های ستاره‌ای.

۱. مقدمه

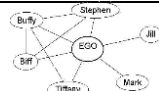

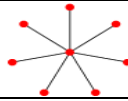
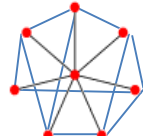
شبکه‌های اجتماعی بر خط به عنوان یک حوزه تحقیقاتی پرطرفدار، توجه پژوهشگران فراوانی را به خود جلب کرده‌است. در حال حاضر، تقریباً هر حوزه‌ای مثل سرگرمی، آموزش، تجارت، کسب و کار، ارتباطات و ... متأثر از این شبکه‌ها می‌باشد. مشهورترین این شبکه‌ها، فیسبوک، در حدود ۲,۲۷ میلیارد نفر کاربر به صورت ماهانه دارد [۱]. تمایل افراد به ارتباط با یکدیگر و اشتراک‌گذاری اطلاعات باعث رشد سریع و روزافزون این شبکه‌ها شده‌است.

مطالعات بسیاری بر روی جنبه‌های مختلف این شبکه‌ها انجام شده- است. یکی از جنبه‌های مهم تحلیل شبکه‌های اجتماعی بررسی حضور ناهنجاری‌ها است. ناهنجاری‌ها در حوزه شبکه‌های اجتماعی، دلالت بر رفتار نامنظم و اغلب غیرقانونی دارند [۲]. روش‌های بسیاری برای تشخیص انواع ناهنجاری‌ها در شبکه‌های اجتماعی پیشنهاد شده‌اند. بر اساس رویکرد مورداستفاده می‌توان این روش‌ها را در سه دسته مبتنی بر خوشه‌بندی / انجمن، مبتنی بر ساختار شبکه و مبتنی بر پردازش سیگنال دسته‌بندی کرد [۳]. در رویکردهای مبتنی بر خوشه‌بندی، هدف، پیدا کردن ناهنجاری‌ها بعد از خوشه‌بندی یا تشخیص انجمن‌ها می‌باشد. دومین دسته رویکردهای مبتنی بر ساختار شبکه است. از ساختار شبکه داده‌شده برای استخراج ویژگی‌های ساختاری گراف‌محور مانند، تعداد گره‌ها، تعداد یال‌ها، مرکزیت بینابینی هر گره و غیره استفاده می‌کنند. انواع ناهنجاری‌هایی که توسط روش‌های تشخیص ناهنجاری در شبکه‌های اجتماعی مبتنی بر ساختار تشخیص داده می‌شوند، شامل رأس ناهنجار، یال ناهنجار و زیرگراف ناهنجار است [۳]. اگر هدف

شناسایی کاربرانی در شبکه باشد که رفتارشان از رفتار عادی مورد انتظار، متفاوت است؛ زیرمجموعه‌ای از رأس‌ها به عنوان ناهنجاری‌ها گزارش می‌شوند. اگر هدف، شناسایی فعل و انفعالات غیرقانونی میان کاربران باشد، زیر مجموعه‌ای از یال‌ها به عنوان ناهنجاری‌ها شناسایی می‌شوند و در نهایت در تشخیص زیر گراف ناهنجار، هدف پیدا کردن گروه‌هایی از افراد در شبکه است که الگوهای تعامل بین آن‌ها در مقایسه با رأس‌های دیگر در شبکه غیرعادی است که به این نوع ناهنجاری‌ها، ناهنجاری به لحاظ اتصال^۱ نیز گویند. شناسایی گره‌های هدف در گذشته کمتر مورد بوده‌است [۴][۵]. در حالی که شناسایی عوامل دیگر در صدر مطالعات بسیاری از محققان [۶] [۷] بوده‌است.

برخی از معیارهای ساختاری گراف (تعداد گره، یال‌ها، مقادیر ویژه، مرکزیت بینابینی و...) برای شناسایی ناهنجاری‌ها در شبکه‌های اجتماعی استفاده شده‌است، اما در راستای تلاش برای بهبود دقت و کاهش تعداد مثبت و منفی‌های کاذب، دیگر معیارهای گراف (مانند واسط یا Brokerage) نیز می‌تواند برای تشخیص ناهنجاری‌ها در شبکه‌های اجتماعی واقعی به‌کار رود. با توجه به نوع ناهنجاری‌هایی که در این پژوهش مورد توجه قرار گرفته‌است، اجرای کار پیشنهادی بر روی گراف‌های ساده ایستا انجام شده‌است. بر این اساس، ویژگی‌های میانی مختلف گراف مبتنی بر ساختار همسایگان هر گره (Egonet) مورد مطالعه و بررسی قرار گرفته‌اند. برازش منحنی، تحلیل رگرسیون و تخصیص نمره غیرعادی به گره، به شناسایی و رتبه‌بندی ناهنجاری‌ها مطابق درجه ناهنجاری آن‌ها کمک می‌کند. برخی از اصطلاحات دیگر مرتبط با کار ما که اغلب در این زمینه استفاده می‌شود در جدول ۱ ارائه شده‌است.

جدول ۱: اصطلاحات مهم

واژه	تعریف	ملاحظات
Ego	یک Ego یک شخص در گراف است.	
Egonet	گراف دوستان سطح یک یک گره (دوستان یک کاربر) یک ساختار egonet را تعریف می‌کند.	
Near Star	یک شبکه با مجموعه‌ای گره‌های تقریباً منفصل، یک شبکه ستاره‌ای نزدیک را نمایش می‌دهد.	
Near Clique	یک شبکه با مجموعه‌ای تقریباً تمام متصلی از گره‌ها، کلاس نزدیک را نمایش می‌دهد.	
Betweenness Centrality (BC) مرکزیت بینابینی	مرکزیت بینابینی به عنوان تعدادی از کوتاه‌ترین مسیر بین هر جفت از گره‌ها در شبکه تعریف شده‌است که از طریق «ا» به‌وسیله تعداد کل کوتاه‌ترین مسیر بین این رأس‌ها عبور می‌کند [۴].	این در پیش‌بینی مرکزی‌ترین گره در شبکه و بنابراین جریان اطلاعات کمک می‌کند.
Average Betweenness Centrality (ABC)	ABC یک گره در داخل egonet است که به عنوان میانگین مرکزیت بینابینی آن گره و مرکزیت بینابینی همه گره‌ها در آن egonet تعریف شده‌است. [۵]	این نشان‌دهنده پیشرفت مرکزیت بیتابینی یک گره با شناسایی با نفوذترین گره در

۲. کارهای مرتبط با شناسایی زیرگراف‌های غیرمعمول

شناسایی گره‌های هدف در گذشته کمتر مورد توجه قرار گرفته [۴] [۵] در حالی که شناسایی عوامل دیگر در صدر مطالعات بسیاری از محققان [۶] [۷] بوده است. به منظور شناسایی اجزای غیرعادی فوق، تکنیک‌های تشخیص غیرعادی مبتنی بر رفتار، مبتنی بر ساختار و مبتنی بر طیف طبقه‌بندی شده‌اند. روش‌های مبتنی بر رفتار [۹] [۱۰] با ویژگی‌های رفتاری افراد که شامل تعداد و محتوای پیام‌ها، تعداد لایک‌ها یا کامنت‌های یک پست (متن)، مدت زمان مکالمه، محتوای موارد به اشتراک گذاشته شده، سروکار دارند. روش‌های مبتنی بر ساختار [۱۳] [۱۲] [۱۱] با ویژگی‌های ساختاری شبکه سروکار دارند. چنین روش‌هایی ممکن است شامل استفاده از تعدادی از معیارهای گراف برای تعیین فعالیت‌های غیرعادی [۱۱] [۱۴] باشد. روش‌های مبتنی بر طیف [۱۵] [۱۶] با اندازه‌گیری‌های گرافیکی پیچیده مانند مقادیر ویژه و بردار ویژه مرکزیت‌ها^۲ یا با الگوریتم‌های آبرگراف پیچیده سروکار دارند. همانطور که در [۱۳] توضیح داده شده است، روش‌های مبتنی بر ساختار سودمندترند، زیرا تقلید و ساختن ویژگی‌های ساختاری و فراداده‌هایی که در ساختار شبکه‌ها وجود دارد، برای کاربر مشکل است. در رویکردهای دیگر، یک کاربر می‌تواند برخی از روش‌های فرار، از قبیل پنهان کردن هویت و دادن اطلاعات نادرست در مورد نمایه، سن، شغل و سایر ویژگی‌های نمایه‌شان را به کار ببندد تا از شناسایی جلوگیری کرده و در نتیجه عموم را فریب دهد، اما مخفی کردن (ساختاری) فراداده همچون ارتباطاتی که یک کاربر با گره‌های دیگر دارد، بسیار دشوار است.

ویژگی‌های ساختاری در یک شبکه مانند تعداد و نوع اتصالات بین گره‌ها، تراکم (چگالی) گراف، مواردی هستند که انکار آن‌ها برای کاربر دشوار است و از این رو کارکردن روی آن مهم است. به عنوان مثال، به منظور گسترش هرزنامه‌ها، هرزنامه‌نویسان معمولاً برای ایجاد پروفایل‌های جعلی یا سوء استفاده از حساب‌های قانونی انتخاب شده، هدف اصلی خود را بزرگ و متصل به هم قرار داده و به دنبال این، آن‌ها گسترش دایره ای خود را به‌طور تصادفی ادامه می‌دهند. تشخیص چنین افرادی با استفاده از ویژگی‌های رفتاری و نمایه‌ای کمک زیادی نخواهد کرد زیرا اگر پروفایل‌ها جعلی باشند، این اطلاعات رفتاری در ظاهر مشروع خواهد بود. علاوه بر این، تجزیه و تحلیل محتوای پست‌ها و پیام‌ها یک روش بسیار پیچیده و خسته‌کننده است. اما مشخصات ساختاری مانند چگالی گراف، مرکزیت گره به طور خودکار توسعه یافته و جعل آن‌ها در دست کاربر نیست.

ویژگی‌های ساختاری گره‌ها توسط بسیاری از محققان برای تحلیل الگوهای مختلف در میان گره‌ها استفاده شده است. شناسایی روابط غیر عادی با استفاده از کشف لینک غیرعادی (ALD) [۱۷]، تشخیص

لینک‌های ازدست‌رفته و خراب با استفاده از استخراج پیوند ساختاری [۱۸]، تشخیص کاربران و پیام‌های غیرعادی با استفاده از همکاری‌های خوشه‌بندی [۱۹]، تشخیص رهبران تفکرات خاص با استفاده از معیارهای اعتماد [۲۰]. محققان همچنین استفاده از معیارهای گراف را برای تشخیص گره‌ها و الگوهای غیرعادی به کار بسته‌اند. به عنوان مثال، Akoglu و همکاران [۱۱] الگوریتمی به نام Oddball را که تعدادی از قوانین قدرت را برای تشخیص سه نوع مختلف ناهنجاری‌ها، یعنی نزدیک ستاره‌ها / دسته‌ها، لبه‌های غالب و همسایگی سنگین پیشنهاد کرده است.

رضا و همکاران [۱۳] استفاده از برخی از معیارهای جدید مانند، ABC (میانگین مرکزیت بینابینی) و انجمن انسجام را برای پیش‌بینی ناهنجاری‌های نزدیک ستاره‌ای / دسته‌ای پیشنهاد کرده‌اند. رضایی و همکاران [۱۲] نیز روش مشابهی را با پیروی از رابطه بین تعداد گره‌ها و لبه‌ها در مجموعه داده‌های توپیتر برای تشخیص چنین ناهنجاری‌هایی مورد استفاده قرار داده‌اند. هندرسون و همکاران [۱۴] بر روی ویژگی‌های مبتنی بر گره و مبتنی بر egonet کار کرده‌اند. آن‌ها ویژگی‌های موجود را با استفاده از محاسبه مقادیر جمع شده خاص طبق ویژگی‌های موجود به صورت بازگشتی تجزیه و تحلیل کرده‌اند. Trifunovic و همکاران [۲۱] نزدیکی اتصالات برای یافتن اعتماد^۳ اجتماعی صریح و ضمنی در شبکه‌های فرصت‌طلبانه^۴ را به کار برده‌اند. سینگ و همکاران [۲۲] از معیارهای گراف از قبیل درجه خروجی^۵ و درجه ورودی^۶ همراه با رتبه داده شده به ویژگی‌های مختلف به عنوان یک عامل قابل اعتماد بودن افراد در شبکه‌های اجتماعی مبتنی بر وب، استفاده کردند. اقدام و نویمپور [۲۰] از عواملی مانند روابط اجتماعی، محتوای اطلاعات متنی و روابط اعتماد برای یافتن سرگروه‌های یک تفکر در شبکه‌های اجتماعی استفاده کردند. بر اساس شباهت ساختاری و همچنین اجتماعی در میان گره‌ها، ضریب تشابه جاکارد محاسبه شد. سرگروه‌های نظرات بر اساس ارزش اعتماد محاسبه شده از نظرات کاربران انتخاب شدند. برخی از برنامه‌های کاربردی، با تخصیص یک عدد مبنی بر درجه پرت بودن هر شیء، بر میزان رفتار غیرعادی تمرکز کرده‌اند. این درجه به عنوان عامل پرت محلی (LOF^۷) توسط Breunig و همکاران اشاره شده است [۲۴]. در این پژوهش اثربخشی واسطه برای تشخیص ناهنجاری ستاره‌ای نزدیک / دسته‌ای و مقایسه آن با دیگر معیارهای گراف مانند N نسبت به E و ABC نسبت به E را مورد بررسی قرار گرفته است.

۳. شناسایی ناهنجاری‌ها

کار حاضر ترکیبی از نظریه گرافیکی و آماری است. اولاً، معیارها و ساختارهای مختلف گراف محاسبه می‌شوند و بعد از آن برای شناسایی و تجزیه و تحلیل ساختارهای غیرمعمول (ستاره‌ها و دسته‌ها) از روش‌های آماری استفاده می‌شود.

۱.۳. انتخاب معیارهای گراف تشخیص ناهنجاری

تعدادی از معیارهای گراف در یک شبکه وجود دارد که می‌تواند مورد بررسی و تحلیل قرارگیرد. معیارهای گراف مورد استفاده در این کار شامل تعداد گره، لبه‌ها، میانگین مرکزیت بینابینی و واسط هستند، زیرا به نظر می‌رسد که تعریف آن‌ها مناسب‌ترین نوع تشخیص نوع ناهنجاری‌هایی است که در پژوهش مورد توجه قرار گرفت. برای انجام کلیه محاسبات مربوط به ساختار *egonet* و معیارهای مربوط به گراف از نرم‌افزار *Matlab* نسخه 2018a استفاده شد.

۲.۳. محاسبه منحنی برازش

به منظور درک ارتباط بین یک کاربر و دوستانش، رابطه بین معیارهای گراف مشخص شده با استفاده از قوانین توزیع مانند قانون خطی و قدرت مدل‌سازی می‌شود. برای محاسبه نمره غیرعادی برای هر کاربر، یک پیش‌نیاز برای تعریف یک مدل، که می‌تواند یک مدل آماری، مدل رگرسیون، یا سایر مدل‌ها باشد، وجود دارد. انتخاب مدل یک کار مهم است و در این کار، بر استفاده از مدل رگرسیون با استفاده از منحنی برازش برای شناسایی ناهنجاری‌ها تمرکز می‌شود. همانطور که تحلیل رگرسیون یک روش آماری برای تحلیل رابطه بین متغیرهای مختلف است، از این رو برای کار پیشنهادی مناسب‌تر است. وابستگی متقابل بین گره‌های مختلف مورد مطالعه قرار گرفته است و تغییر رفتار یک متغیر به عنوان یک نتیجه از تغییر در دیگر، برای بررسی ارتباط بین معیارهای مختلف تجزیه و تحلیل می‌شود.

۳.۳. محاسبه امتیاز ناهنجاری

امتیاز ناهنجاری با استفاده از فرمول مورد استفاده توسط *Akoglu* و همکاران [۱۱] در الگوریتم *Oddball* و رضا و همکاران [۱۳] در کارشان، محاسبه شده است. فاصله گره از منحنی برازش به شناسایی رفتار غیرعادی کمک می‌کند.

$$ascore(i) = \quad (3-1)$$

$$\frac{\max(y_i, Cx_i^\theta)}{\min(y_i, Cx_i^\theta)} * \log(|y_i - Cx_i^\theta| + 1)$$

فرمول بالا، فاصله هر گره i را از منحنی برازش محاسبه می‌کند. روند مشترک و آشکار بیان می‌کند که گره‌های ناهنجار به دور از منحنی قرار داشته و فاصله آن‌ها از منحنی بیشتر خواهد بود در حالی که گره‌های طبیعی بر روی منحنی یا نزدیک به آن قرار دارند. در حین محاسبه فاصله به عنوان میزان امتیاز، فرمول هر گره را به وسیله مقدار انحراف بین مقدار محاسبه شده (y_i) و مقدار مورد انتظار (Cx_i^θ) همراه با لگاریتم میزان

انحراف جریمه می‌کند. آن y و x نشانگر معیارهای گراف هستند و θ مربوط به شاخص قدرت قانون است.

۴.۳. برچسب گذاری گره‌ها

گره‌های ناهنجار با استفاده از مجموعه ای خاص از محاسبات ریاضی و کدهای برنامه‌نویسی در *MATLAB* برچسب گذاری می‌شوند. فرمول‌های مورد استفاده برای برچسب گذاری ساختار ستاره و دسته در گره‌ها به شرح زیر است:

برای یک ساختار دسته، تعداد لبه‌های اطراف یک گره از الگوی $n(n-1) / 2$ پیروی می‌کند که نشان‌دهنده حداکثر اتصالات است. به طور مشابه، در مورد ساختار ستاره یک گره تنها حدود $(n-1)$ گره در مجاورت خود (و یا *egonet*) دارد. همانطور که قبلاً گفته شد، درصد اتصالات میان گره‌ها، *cliqueness* یا *starness* در شبکه را تعیین می‌کند. بنابراین، با نگاه کردن به درصد *cliqueness / starness* و با استفاده از اندازه‌گیری درجه در فرمول فوق، گره‌ها به عنوان داشتن یا نداشتن ساختار دسته/ستاره‌ای برچسب گذاری می‌شوند. هدف اصلی این کار، بررسی اثربخشی معیارهای مختلف برای تشخیص ناهنجاری‌های تعریف شده است. با استفاده از چنین نمونه‌های برچسب گذاری شده، اثربخشی اقدامات مختلف مورد بررسی قرار می‌گیرد.

در پایان، مقدار آستانه روی امتیازهای ناهنجاری که برای هر معیار محاسبه می‌شود، تنظیم می‌شود تا آندره *F-score* را به حداکثر برساند. هدف نهایی این است که تعداد مثبت‌ها و منفی‌های کاذب که ممکن است با آن‌ها مواجه شود، به حداقل برسد. مقادیر آستانه با استفاده از حساسیت / اختصاصیت نسبت به نمره طرح، به دنبال هر مقدار ممکن که بتواند به همان اندازه عمل کند، تعیین می‌شود. ناحیه (ROC) منحنی (AUC) برای مقادیر مختلف اندازه‌گیری کمک می‌کند تا بهترین اندازه شناسایی شود.

در این پژوهش الگوهای محلی شبکه به جای سناریوی سراسری تحلیل می‌شود زیرا الگوهای محلی می‌توانند اطلاعات خوب و قابل اعتماد در مورد مفهوم سراسری را نیز ارائه دهند. البته هر دو مفهوم مرتبط هستند. ویژگی‌های محلی در استخراج الگوها در یک *egonet* کمک می‌کنند در حالی که الگوهای سراسری، قوانین استخراج شده را برای تعریف رفتار کاربران مختلف تعمیم می‌دهند. بنابراین، برای تشخیص ناهنجاری، اگر هر کاربر مشخص در فضای ویژگی‌های محلی خود (*egonet*) از الگوی کلی تعریف شده توسط فاکتورهای سراسری پیروی کرد آن را عادی و در غیر این صورت ناهنجاری در نظر گرفته می‌شود. علاوه بر این، ساختار پیوند که نشان‌دهنده ستاره‌ها یا دسته‌ها است، بهتر است از دید محلی تجزیه و تحلیل شود، زیرا تمرکز اصلی تجزیه و تحلیل ارتباطات، در *egonet* می‌باشد.

۴. نتایج ارزیابی‌ها

کار پیشنهادی در سه مجموعه داده جمع‌آوری شده از وب سایت <http://networkrepository.com/> استفاده شده است که

که در هر یک از این شبکه‌ها، وجود ساختارهای نزدیک به حالت ستاره‌ای / دسته‌ای در egonet کاربر، رفتار ناهنجار را نشان می‌دهد.

شامل دسته بندی از مجموعه داده‌های مربوط به زمینه‌های مختلف است که شبکه‌های اجتماعی یکی از آنها است. در جدول ۲، جزئیات هر یک از مجموعه داده‌ها ارائه شده است. ما چهار مجموعه داده را پوشش دادیم

جدول ۲: شرح مجموعه داده‌ها.

SOCFB-MICHIGAN23	SOCFB-A-ANON	SOC-FLICKR	SOC-DIGG	مجموعه داده
شبکه دوستی در فیسبوک	شبکه دوستی در فیسبوک	شبکه اجتماعی اشتراک تصویر	شبکه خبری	نوع شبکه
۳۰,۱۴۷	۳,۰۹۷,۱۶۵	۵۱۳,۹۶۹	۷۷۰,۷۹۹	تعداد گره‌ها
۱,۱۷۶,۵۱۴	۲۳,۶۶۷,۳۹۲	۳,۱۹۰,۴۵۳	۵,۹۰۷,۱۳۳	تعداد یال‌ها
رابطه اجتماعی/دوستی	رابطه اجتماعی/دوستی	روابط دوستی	روابط کاربران	نوع ارتباطات
شبه‌ستاره/دسته	شبه‌ستاره/دسته	شبه‌ستاره/دسته	شبه‌ستاره/دسته	نوع ناهنجاری یافت شده

عادی روی منحنی یا در نزدیکی آن قرار می‌گیرند در حالی که گره‌های ناهنجار دورتر از منحنی قرار می‌گیرند. همچنین معیاری مثل مقدار آستانه از لحاظ فاصله (نمره ناهنجاری) به گونه‌ای تنظیم می‌شود تا حد مجاز (فاصله مجاز جهت عادی بودن) را تعیین کند. مقدار آستانه باید به مقداری تنظیم شود که تعداد مثبت و منفی کاذب به حداقل برسد تا دقت بالاتر را به دست بیاورد. F-score به عنوان یک واحد اندازه‌گیری برای تعیین دقت معیارهای مختلف استفاده می‌شود. محاسبه نمره غیرعادی با استفاده از فرمول بیان شده در معادله (۱-۳) به شناسایی ناهنجاری‌ها در مجموعه داده‌ها کمک می‌کند.

برای شناسایی ناهنجاری‌ها، برخی از معیارهای مهم گراف مانند تعداد گره‌ها، لبه‌ها، مرکزیت بینابینی و واسط ابتدا از لحاظ نظری مورد بررسی و سپس عملاً برای بررسی اثربخشی آنها مورد استفاده قرار گرفت. به منظور تشخیص ناهنجاری، فرمول مبتنی بر فاصله ذکر شده در معادله (۱-۳) استفاده شده است که فاصله یک گره را از منحنی برازش محاسبه می‌کند. به دلیل مقدار بالای واسط و تعداد کم لبه‌ها در ساختار egonet، چنین گره‌ای در جایی در بخش پایین سمت راست قرار خواهد گرفت. بدیهی است که این نوع از گره‌ها دورتر از منحنی قرار خواهند گرفت. پس از محاسبه منحنی‌های برازش، فاصله گره از منحنی برازش برای تعیین گره‌های ناهنجار به کار می‌رود. گره‌های

جدول ۳: مقایسه اثرگذاری معیارهای مختلف گراف

F-Score(%)	Recall (%)	دقت (%)	منحنی برازش	روش	مجموعه داده
۵۲,۴۴	۶۷,۶۷	۴۲,۸۱	$E = 0.03492B + 516.7$	B نسبت به E (قانون خطی)	SOC-DIGG
۳۲,۸۶	۸۴,۱۲	۲۰,۴۲	$E = 29.41ABC - 634.2$	ABC نسبت به E (قانون خطی)	
۴۶,۲۲	۳۳,۶۰	۷۴,۰۰	$E = 26.63N - 1294$	N نسبت به E (قانون خطی)	
۸۵,۳۹	۹۲,۶۳	۷۹,۲۱	$E = 2.569 \times B^{0.6773}$	B نسبت به E (قانون قدرت)	
۸۳,۸۰	۸۰,۷۱	۸۷,۱۴	$E = 25.1 \times ABC^{1.013}$	ABC نسبت به E (قانون قدرت)	SOC-FLICKR
۸۲,۸۶	۸۸,۳۰	۷۸,۰۶	$E = 1.38 \times N^{1.445}$	N نسبت به E (قانون قدرت)	
۴۸,۵۵	۴۷,۵۹	۵۱,۶۵	$E = 0.03357B + 1555$	B نسبت به E (قانون خطی)	
۳۳,۳۶	۲۷,۰۷	۴۳,۴۵	$E = 79.94ABC - 1917$	ABC نسبت به E (قانون خطی)	
۲۱,۸۶	۱۰۰,۰۰	۱۲,۲۷	$E = 71.9N - 3717$	N نسبت به E (قانون خطی)	SOCFB-A-ANON
۸۳,۱۴	۷۹,۱۶	۸۷,۵۴	$E = 13.45 \times B^{0.6179}$	B نسبت به E (قانون قدرت)	
۸۰,۵۵	۶۷,۴۳	۱۰۰,۰۰	$E = 63.61 \times ABC^{1.022}$	ABC نسبت به E (قانون قدرت)	
۸۲,۱۹	۷۴,۳۹	۹۱,۸۰	$E = 8.124 \times N^{1.302}$	N نسبت به E (قانون قدرت)	
۲۲,۵۹	۱۷,۵۶	۳۱,۶۷	$E = 0.0061B + 320.5$	B نسبت به E (قانون خطی)	SOCFB-A-ANON
۱۹,۷۰	۱۰۰,۰۰	۱۰,۹۳	$E = 8.349ABC - 144.4$	ABC نسبت به E (قانون خطی)	
۲۲,۱۹	۱۲,۴۸	۱۰۰,۰۰	$E = 8.011N - 240.5$	N نسبت به E (قانون خطی)	
۷۷,۳۰	۸۲,۴۰	۷۲,۷۹	$E = 2.343 \times B^{0.5943}$	B نسبت به E (قانون قدرت)	
۶۸,۸۴	۷۸,۹۲	۶۱,۰۴	$E = 3.778 \times ABC^{1.121}$	ABC نسبت به E (قانون قدرت)	
۷۲,۴۰	۸۵,۸۹	۶۲,۵۷	$E = 1.998 \times N^{1.211}$	N نسبت به E (قانون قدرت)	
۶۱,۴۰	۹۷,۲۲	۴۴,۸۷	$E = 0.0502B + 543.2$	B نسبت به E (قانون خطی)	

۶۰,۶۶	۴۷,۴۴	۸۴,۰۹	$E = 98.44ABC + 1205$	ABC نسبت به E (قانون خطی)
۶۰,۹۸	۶۴,۱۰	۵۸,۱۴	$E = 21.41 N - 1043$	N نسبت به E (قانون خطی)
۸۵,۳۱	۷۸,۲۱	۹۳,۸۵	$E = 1.789 \times B^{0.7072}$	B نسبت به E (قانون قدرت)
۷۸,۴۳	۷۶,۹۲	۸۰,۰۰	$E = 1603 \times ABC^{0.309}$	ABC نسبت به E (قانون قدرت)
۸۴,۴۴	۷۳,۰۸	۱۰۰	$E = 0.9947 \times N^{1.505}$	N نسبت به E (قانون قدرت)

معیارها محاسبه می‌شود و یکی از موارد با بالاترین دقت و صحت به عنوان بهترین مقدار انتخاب می‌شود.

مقدار آستانه نسبت به نوع مجموعه داده‌هایی که بر روی آن‌ها کار می‌کنیم، عدد متفاوتی خواهد بود. مقادیر آستانه برای هر یک از معیارهای مورد بحث به صورت جدول زیر به دست آمده است:

تنظیم مقدار آستانه با نسبت حساسیت/خصوصیت نسبت به نمره Score انجام می‌شود که این به انتخاب بهترین آستانه از تمام مقادیر ممکن که می‌توان در نظر گرفت، کمک می‌کند. همانطور که در مرحله ۹ شبه‌کد گفته شد، برای هر مقدار ممکن آستانه، پارامترهای مختلف مانند دقت، جامعیت، صحت و اندازه‌گیری F-Score برای هر مجموعه از

جدول ۳: محاسبه مقدار آستانه امتیازهای به دست آمده

مقدار آستانه	F-Score(%)	روش	مجموعه داده
۰,۱۴	۵۲,۴۴	B نسبت به E (قانون خطی)	SOC-DIGG
۰,۸۸	۳۲,۸۶	ABC نسبت به E (قانون خطی)	
۰,۱۲	۴۶,۲۲	N نسبت به E (قانون خطی)	
۰,۱۰	۸۵,۳۹	B نسبت به E (قانون قدرت)	
۰,۳۶	۸۳,۸۰	ABC نسبت به E (قانون قدرت)	
۰,۰۸	۸۲,۸۶	N نسبت به E (قانون قدرت)	
۰,۵۲	۴۸,۵۵	B نسبت به E (قانون خطی)	SOC-FLICKR
۰,۶۲	۳۳,۳۶	ABC نسبت به E (قانون خطی)	
۰,۰	۲۱,۸۶	N نسبت به E (قانون خطی)	
۰,۳۰	۸۳,۱۴	B نسبت به E (قانون قدرت)	
۰,۵۴	۸۰,۵۵	ABC نسبت به E (قانون قدرت)	
۰,۲۸	۸۲,۱۹	N نسبت به E (قانون قدرت)	
۰,۴۶	۲۲,۵۹	B نسبت به E (قانون خطی)	SOCFB-A-ANON
۰,۸۲	۱۹,۷۰	ABC نسبت به E (قانون خطی)	
۰,۱۸	۲۲,۱۹	N نسبت به E (قانون خطی)	
۰,۱۸	۷۷,۳۰	B نسبت به E (قانون قدرت)	
۰,۰۸	۶۸,۸۴	ABC نسبت به E (قانون قدرت)	
۰,۱۶	۷۲,۴۰	N نسبت به E (قانون قدرت)	
۰,۶۲	۶۱,۴۰	B نسبت به E (قانون خطی)	SOCFB-MICHIGAN23
۰,۴۴	۶۰,۶۶	ABC نسبت به E (قانون خطی)	
۰,۳۲	۶۰,۹۸	N نسبت به E (قانون خطی)	
۰,۴۶	۸۵,۳۱	B نسبت به E (قانون قدرت)	
۰,۴۸	۷۸,۴۳	ABC نسبت به E (قانون قدرت)	
۰,۵۰	۸۴,۴۴	N نسبت به E (قانون قدرت)	

از مجموعه داده‌های پژوهش برای هر یک از رابطه‌های B نسبت به E، ABC نسبت به E و N نسبت به E به شکل جدول زیر محاسبه شده است:

منحنی ROC و سطح زیر منحنی (AUC) در شکل‌های صفحات بعدی برای کلیه مجموعه داده‌های این پژوهش نشان داده شده است. تجزیه و تحلیل آماری و بصری نشان می‌دهد که منطقه تحت پوشش منحنی برای رابطه B نسبت به E حداکثر است. مقدار AUC برای باقی‌مانده هر یک

جدول ۴: محاسبه مقدار سطح زیر نمودار (AUC)

مجموعه داده	قانون قدرت / خطی	B نسبت به E	ABC نسبت به E	N نسبت به E
SOC-DIGG	قانون قدرت	۹۳,۵۷	۸۹,۰۱	۹۱,۳۵

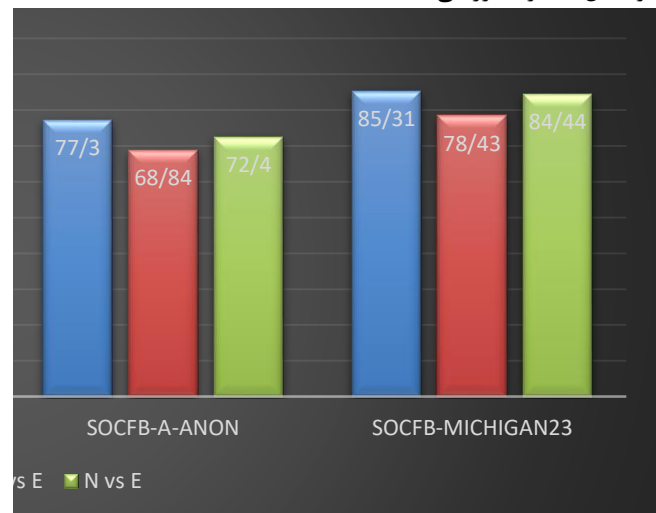
۶۵,۴۷	۵۵,۰۸	۷۳,۶۳	قانون خطی	SOC-FLICKR
۸۶,۷۳	۸۳,۷۱	۸۸,۷۹	قانون قدرت	
۵۰,۰۰	۶۱,۰۷	۶۹,۸۹	قانون خطی	SOCFB-A-ANON
۸۹,۷۲	۸۶,۳۷	۸۹,۳۱	قانون قدرت	
۸۹,۷۹	۵۰,۰۱	۵۶,۴۵	قانون خطی	SOCFB-MICHIGAN23
۷۷,۵۶	۵۱,۲۲	۸۸,۴۱	قانون قدرت	
۸۳,۵۶	۵۳,۰۳	۶۰,۱۲	قانون خطی	

ناهنجاری‌ها را پیش‌بینی و گره‌ها را با توجه به رفتار غیرمنطقی آن‌ها رتبه‌بندی کنند.

مراجع

- [1] <https://zephoria.com/top-15-valuable-facebook-statistics/>
- [2] D. Savage, X. Zhang, X. Yu, P. Chou, and Q. Wang, "Anomaly detection in online social networks," J. Soc. Netw, vol. 39, pp. 62-70, Octobr 2014.
- [3] P. Bindu and P. S. Thilagam, "Mining social networks for anomalies: Methods and challenges," J. Netw.Comput.Appl, vol. 68, pp. 213-229, June 2016.
- [9] L. Akoglu, M. McGlohon, and C. Faloutsos, "Oddball: Spotting anomalies in weighted graphs," in Proce. Int. Conf. on Knowledge Discovery and Data Mining, pp. 410-421, June 2010.
- [4] Li H, Bhowmick SS, Sun A. Blog cascade affinity: analysis and prediction. In: Proceedings of the 18th ACM conference on information and knowledge management; 2009. p. 1117-26.
- [۵] Li H, Bhowmick SS, Sun A, Cui J. Affinity-driven blog cascade analysis and prediction. Data Min Knowl Discov 2014;28(2):442-74.
- [۶] Agarwal N, Liu H, Tang L, Yu PS. Identifying the influential bloggers in a community. In: Proceedings of the 2008 international conference on web search and data mining; 2008. p. 207-18.
- [۷] Cai K, Bao S, Yang Z, Tang J, Ma R, Zhang L, et al. OOLAM: an opinion oriented link analysis model for influence persona discovery. In: Proceedings of the fourth ACM international conference on web search and data mining; 2011. p. 645-54.
- [۸] M. Newman, Networks: an introduction: Oxford university press, 2010.
- [۱۱] L. Akoglu, M. McGlohon, and C. Faloutsos, "Oddball: Spotting anomalies in weighted graphs," in Proce. Int. Conf. on Knowledge Discovery and Data Mining, pp. 410-421, June 2010.
- [13] R. Hassanzadeh, R. Nayak, and D. Stebila, "Analyzing the effectiveness of graph metrics for anomaly detection in online social networks," in Int. Conf. on Web Inf. Syst. Eng., 2012, pp. 624-630.
- [۹] Vanetti M, Binaghi E, Carminati B, Carullo M, Ferrari E. Content-based filtering in on-line social networks. In: Privacy and security issues data mining and machine learning; 2011. p. 127-40.
- [10] Viswanath B, Bashir MA, Crovella M, Guha S, Gummadi KP, Krishnamurthy B. Towards detecting anomalous user behavior in online social networks. In: Proceedings of the 23rd USENIX security symposium (USENIX security); 2014. p. 223-38.
- [12] Rezaei A, Kasirun ZM, Rohani VA, Khodadadi T. Anomaly detection in online social networks using structure-based technique. In: 8th international conference for internet technology and secured transactions (ICITST); 2013. p. 619-22.

از این رو به نظر می‌رسد کارگزار(واسط) مقیاسی است که به‌درستی می‌تواند بسیاری از ناهنجاری‌ها را تشخیص دهد. با توجه به جدول ۳ می‌توان گفت که رابطه بین واسط (B) نسبت به تعداد لبه‌ها (E) به پیش بینی اکثر ناهنجاری‌ها کمک می‌کند. در جدول ۴، رابطه بین معیارهای مختلف گراف نشان داده شده است. برای هر یک از مجموعه داده‌ها، مقادیری برای پارامترهای مختلف مانند دقت، Recall و F-Score محاسبه شده و مشاهده می‌شود که استفاده از مقدار واسط در مدل عملکرد بهتری از مقیاس‌های موجود ارائه شده در روش "Oddball" [۱۱] و مرکزیت بینابینی در [۲۱] دارد. نتایج از نظر آماری با استفاده از محاسبه نمره F-Score و همچنین بررسی گرافیکی در شکل ۱ نمرات ارزیابی شده‌اند.



شکل ۱. مقایسه مقادیر F-Score اندازه‌گیری‌های B نسبت به E. ABC نسبت به E و N نسبت به E برای مجموعه داده‌های مختلف

۵. نتیجه‌گیری

در این پژوهش، استفاده از معیارهای گراف در پیش‌بینی ناهنجاری‌ها و تأکید بر اهمیت روش‌های مبتنی بر ساختار ارائه شد. روش برازش منحنی مبتنی بر ساختار گراف، برای تشخیص ناهنجاری‌ها با استفاده از ترکیب معیارهای جدید گراف و بیان اهداف نظری و عملی آن‌ها، گسترش داده شد و مشاهده شد که رابطه میان واسط و لبه‌ها به پیش‌بینی تعداد زیادی از ناهنجاری‌ها که یا به اشتباه طبقه‌بندی شده بودند و یا با روش Oddball و رابطه ABC نسبت به E نادیده گرفته شده بود، کمک کرد. نمرات غیرعادی تخصیصی به گره‌ها کمک می‌کند تا میزان

- [14] Henderson K , Gallagher B , Li L , Akoglu L , Eliassi-Rad T , Tong H . It's who you know: graph mining using recursive structural features. In: Proceedings of the 17th ACM SIGKDD international conference on knowledge discovery and data mining; 2011. p. 663–71 .
- [15] Ying X , Wu X , BarbaráD . Spectrum based fraud detection in social networks. In: Proceedings - international conference on data engineering; 2011. p. 912–23 .
- [16] Miller B , Beard M , Wolfe P , Bliss N . A spectral framework for anomalous subgraph detection. *IEEE Trans Signal Process* 2014;63(16):4191–206 .
- [17] Rattigan MJ , Jensen D . The case for anomalous link discovery. *ACM SIGKDD Explorations Newsletter* 2004;7(2):41–7 .
- [18] Zheleva E , Getoor L , Golbeck J , Kuter U . Using friendship ties and family circles for link prediction. In: *Advances in social network mining and analysis*; 2010. p. 97–113 .
- [19] Yang W , Shen G-W , Wang W , Gong L-Y , Yu M , Dong G-Z . Anomaly detection in microblogging via co-clustering. *J Comput Sci Technol* 2015;30(5):1097–108 .
- [20] Aghdam SM , Navimipour NJ . Opinion leaders selection in the social networks based on trust relationships propagation. *Karbala Int J Mod Sci* 2016;2(2):88–97 .
- [21] Trifunovic S , Legendre F , Anastasiades C . Social trustin opportunistic networks. In: *INFOCOM IEEE conference on computercommunications work- shops*; 2010. p. 1–6 .
- [22] Singh S , Sidhu J . An approach for determining trustworthiness of individuals in a web-based social network. *Arab J Sci Eng* 2016;41(2):461–77 .
- [23] Breunig MM , Kriegel H-P , Ng RT , Sander J . LOF: identifying density-based local outliers. *ACM Sigmod Rec* 20 0;29(2):93–104 .
- [24] Eberle W , Holder L . Anomaly detection in data represented as graphs. *Intell Data Anal* 2007;11(6):663–89 .

پی‌نوشت

1. Connectivity
2. Eigenvector Centralities
3. Trust
4. Opportunistic Networks
5. Out-Degree
6. In-Degree
7. Local Outlier Factor