

## مدل سازی رفتار بازنشر کاربران در اجتماعات برخط با استفاده از تیمی از اتوماتاهای یادگیر

امیدرضا بلوکی اسپیلی<sup>۱\*</sup> و احمد آقا کاردان<sup>۲</sup>

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۳۹۷/۱۲/۰۱ پذیرش مقاله: ۱۳۹۸/۰۳/۰۱	<p>امروزه اجتماعات برخط، در گردش اطلاعات نظیر اخبار، محتوای آموزشی، مطالب سرگرم کننده و غیره نقش مهمی دارند. میلیون ها کاربر به صورت روزانه پست های مختلف را در این محیط، ایجاد می نمایند. کاربران در صورت تمایل، برخی از پست را بازنشر می کنند. بازنشر یک پست در انتقال اطلاعات بین کاربران تأثیر اساسی دارد. با توجه به تعداد زیاد پست ها، کاربران در این گونه اجتماعات با مشکل گرانباری اطلاعات مواجه هستند. این مسئله موجب کاهش بازنشر پست ها و اختلال در انتقال اطلاعات در اجتماعات برخط شده است. در این مقاله، رفتار بازنشر کاربران در مواجهه با پست های مختلف، مدل سازی شده است. برای این کار در ابتدا متغیرهای مؤثر در مدل رفتار بازنشر کاربران شناسایی شده است و سپس با استفاده از یک روش یادگیری تقویتی، رفتار کاربران در مواجهه با یک پست ها، پیش بینی شده است. این روش یادگیری تقویتی به صورت یک بازی برای تیمی از اتوماتاهای یادگیر تصادفی طراحی شده است. برای ارزیابی، از سه مجموعه داده نسبتاً بزرگ استفاده شده است. بر اساس نتایج بدست آمده، اتوماتاهای یادگیر تصادفی با توجه به ویژگی های محیط و قدرت یادگیری برخط، قابلیت اجرایی بسیار خوبی داشته است.</p>
<p><b>واژگان کلیدی:</b> اجتماعات برخط، تیمی از اتوماتای یادگیر، مدل سازی رفتار کاربر، بازی با سود مشترک.</p>	

### ۱- مقدمه

سازمان ها، محصولات و نام های تجاری<sup>۳</sup> می باشد. کمتر از بیست درصد این توثیتهای مورد توجه کاربران قرار می گیرد. پیش بینی رفتار کاربران در قبال پست های تبلیغاتی که احتمالاً موجب تحریک علاقه آن ها می شود، می تواند فروش و بازاریابی محصولات و نام های تجاری مختلف را بهبود بخشد. آگهی های برخط می توانند با استفاده از مدل سازی رفتاری کاربران، و پیش بینی تصمیم آن ها در مواجهه با این گونه آگهی ها، کاربران را به طور مؤثرتری هدف قرار دهند. علاوه بر این، پیش بینی های موفق تصمیم بازنشر کاربران در مواجهه با پست های تبلیغاتی، می تواند امکان ایجاد محتوای جذاب تر و در نتیجه، افزایش رضایتمندی کاربران

اجتماعات برخط امروزه مکان مناسبی برای ارتباط با کاربران و دریافت نظرات آن ها فراهم آورده است. اطلاعات بسیار مهمی از رفتار، علایق، ترجیحات و نظرات کاربران، در اجتماعات برخط وجود دارد. این اطلاعات کاربردهای فراوانی در زمینه های مختلف دارد. استخراج، ذخیره و تحلیل این اطلاعات نیازمند ارائه روش های هدفمند در حوزه مدل سازی رفتاری کاربران می باشد. در این مقاله، یک روش ساختارمند و کاربردی به منظور مدل سازی رفتار بازنشر کاربران در اجتماع برخط، ارائه شده است. در اجتماع برخط توثیتر، بیش از نوزده درصد از توثیتهای، در ارتباط با

\* پست الکترونیک نویسنده مسئول: Speily@aut.ac.ir

۱. دانشجوی دکتری دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه

صنعتی امیرکبیر.

۲. استادیار، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی

امیرکبیر.

<sup>3</sup> Brand

متغیرهای مؤثر در مدل‌سازی رفتار بازنشر یک کاربر و ارائه روش یادگیری بر اساس این متغیرها می‌باشد. در بخش چهارم، به ارزیابی روش پیشنهادی پرداخته خواهد شد. این ارزیابی‌ها در دو حوزه ارزیابی روش مدل‌سازی و ارزیابی نتایج مدل‌سازی پیشنهادی، می‌باشند.

## ۲- پیشینه تحقیق

درک چگونگی ایجاد یک پست توسط کاربران و انگیزه‌های آن‌ها برای بازنشر یک پست، در مدل‌سازی رفتار بازنشر کاربر در مواجهه با یک پست، دارای اهمیت فراوان است. در واقع، فهمیدن این‌که کاربران چه محتوایی را برای بازنشر انتخاب می‌کنند، می‌تواند به توضیح چرایی بازنشر یک پست خاص و پیش‌بینی آن، کمک کند. این انگیزه‌ها برای تصمیم‌بازنشر در مطالعه‌ی انجام‌شده در [۴] به خوبی بررسی شده‌اند. آن‌ها دلایل اصلی تصمیم‌بازنشر توسط کاربران، را مشخص کرده‌اند. آن‌ها ده انگیزه‌ی مختلف برای بازنشر، نظیر نظر دادن در پست‌ها، انتشار پست‌ها به گیرندگان جدید برای آگاهی دادن به اشخاص یا گروه‌های خاص و ذخیره‌ی پست‌ها برای دسترسی آتی شخصی راه، معرفی کردند. اگرچه تمرکز مطالعه‌ی آن‌ها مدل‌سازی رفتار بازنشر کاربران نیست، اما انگیزه‌های گفته‌شده برای تصمیم‌بازنشر، می‌تواند در تعیین متغیرهای مؤثر برای مدل‌سازی رفتار بازنشر کاربران، مورد استفاده قرار گیرد.

مطالعات دیگری برای یافتن متغیرهای مدل رفتار بازنشر توسط سو و همکارانش در [۵] انجام شده است. آن‌ها سه عامل نهفته از ویژگی‌های پست راه، با استفاده از روش تحلیل مؤلفه‌ی اصلی (PCA) استخراج کرده و تلاش کردند تا آن‌ها را به ویژگی‌های واقعی آشکار، ارتباط دهند. آن‌ها سپس یک مدل خطی برای یافتن احتمال بازنشر معرفی کردند. اگرچه آن‌ها انگیزه‌ی خود را در انتخاب مدل خطی برای پیش‌بینی تصمیم‌بازنشر، نگفتند، درباره‌ی مؤثر بودن روش PCA در یافتن عوامل مهم قابلیت بازنشر نیز، بحثی ارائه ندادند. همچنین آن‌ها تنها آزمایش‌های خود را بر روی مجموعه‌ی محدودی از داده‌هایی که خودشان ارائه دادند، اجرا کردند. آن‌ها نتیجه گرفتند که ویژگی‌های مبتنی بر محتوا نظیر هشتگ و url در قابلیت بازنشر، بسیار مهم هستند. این نتیجه توسط مطالعات بعدی در [۶]، به چالش کشیده شد. در این تحقیق نشان داده شده است که ویژگی‌های

و افزایش سود، را فراهم آورد. شرکت‌های رسانه‌ای می‌توانند از این طریق، محتواهای اثرگذاری برای تبلیغ و بازاریابی محصولات خود تولید کنند. در کمپین‌های سیاسی، اجتماعی و غیره می‌توان از نتایج این پیش‌بینی‌ها برای جلب نظر کاربران و هدف گرفتن موفق آن‌ها، استفاده کرد. از جمله بازاریابی‌های مطرح در حوزه تجارت الکترونیکی، بازاریابی محاوره‌ای<sup>۱</sup> بین کاربران می‌باشد. با پیش‌بینی نوع رفتار یک کاربر در مواجهه با نظر دیگر کاربران در قالب یک پست، می‌توان پست‌هایی که قابلیت اثرگذاری بالایی دارند، ایجاد کرد و در شبکه منتشر نمود. این زمینه در اجتماعات برخط خبری، آموزشی و پرسش و پاسخ نیز کاربرد زیادی دارد. عمده روش‌های ارائه شده در جهت مدل‌سازی رفتار بازنشر کاربران، قابلیت عملیاتی پایینی دارند و در محیط واقعی قابل استفاده نیستند. این مسئله به علت پیچیدگی‌های محیط‌های تصادفی دارای نویز می‌باشد. محیط این مسئله کاملاً ناشناخته بوده و قابل مشاهده نیست. برای مدل‌سازی مسئله در محیط واقعی، هیچ اطلاعی از رفتارهای بعدی کاربران و پست‌هایی که در آینده می‌بیند در اختیار نیست. از دیگر نقاط ضعف روش‌های ارائه شده می‌توان به ارائه یک مدل کلی با استفاده از یادگیری برون خط اشاره کرد. مدل‌های برون خط، با استفاده از مجموعه داده‌های بزرگ ساخته می‌شوند و به طور مداوم لازم است در بازه‌های مختلف از نو ساخته شوند تا تغییرات رفتاری کاربران در مدل‌سازی در نظر بگیرند. به همین جهت نمی‌توان از رهیافت‌های سنتی یادگیری دسته‌ای استفاده کرد. پژوهش‌های زیادی نظیر [۱] برای بهبود تحلیل روی پایگاه داده‌ها و [۲] برای بهبود کار روی مجموعه داده‌ها و [۳] برای تحلیل‌های بلادرنگ داده‌های حجیم صورت گرفته است که در این مسئله قابل استفاده نیستند. استفاده از یادگیری برخط بر خلاف یادگیری دسته‌ای، مشکلاتی نظیر تغییرات مداوم مدل ساخته شده، هزینه‌های روز رسانی مدل به صورت مکرر و کاهش دقت مدل به مرور زمان را نخواهد داشت.

در ادامه در بخش دوم به مرور کارهای انجام شده در حوزه مسئله می‌پردازیم. در این بخش سعی شده است تحلیل جامعی از روند پژوهشی مسئله ارائه گردد. در بخش سوم، روش پیشنهادی ارائه می‌گردد. این بخش شامل تعیین

<sup>۱</sup> Word of Mouth

[۱۳] و طبقه‌بندی بیشین آنتروپی [۱۴] استفاده کردند. تمرکز اصلی مطالعه‌ی آن‌ها بر روی ویژگی‌های محتوایی بود. بنابراین، به عنوان یک محدودیت، کار آن‌ها تنها بر پست‌های انگلیسی انجام شد. همچنین آن‌ها از ویژگی‌هایی نظیر هشتگ که برای پیش‌بینی تصمیم‌بازنشر پست‌ها مفید است، استفاده نکردند. در [۱۵]، از روش تخصیص پنهان دریگله<sup>۲</sup> برای مدل‌سازی رفتار بازنشر کاربران استفاده شده است. این روش قابلیت عملیاتی پایینی در محیط‌های برخط دارد. در [۱۶] مشابه روش [۱۷]، یک روش مبتنی بر شبکه‌های بیزی، برای پیش‌بینی تعداد بازنشرهای یک پست معلوم بر اساس الگوی پخش اولیه آن، ارائه شده است. در این پژوهش، مسئله مدل‌سازی رفتار بازنشر، با مطالعه‌ی الگوی پخش پست‌ها انجام شده است. آن‌ها دریافتند که زمان‌های واکنش به پست‌ها را می‌توان به خوبی با استفاده از یک توزیع نرمال لگاریتمی تخمین زد. در این پژوهش، از شبکه بیزی<sup>۳</sup> برای مدل‌سازی پویایی بازنشرها در طی زمان، استفاده شده است. برخلاف سایر تحقیقات که عموماً مدل‌های یادگیری ویژگی‌محور<sup>۴</sup> هستند، این تحقیق هیچ ویژگی را به شکل مستقیم از پست‌ها یا کاربر دریافت نمی‌کند. در واقع پیش‌بینی تنها بر پایه‌ی الگوهای انتشار قبلی پست‌ها بنا شده است. آن‌ها ادعا می‌کنند که راهکارشان زمانی خوب کار می‌کند که حداقل ۱۰٪ بازنشرهای یک پست، دیده شوند. این موضوع برای ما خیلی جالب نیست چرا که اولاً روشن نیست چه زمانی ۱۰٪ پست‌ها مشاهده می‌گردد، و ثانیاً در مسئله مطرح شده در این مقاله، مدل‌سازی رفتار بازنشر یک کاربر، پیش از انتشار یا مدت کمی پس از انتشار آن‌ها مورد نظر است. در یک تحقیق دیگر [۱۸]، یک مدل وزن دهی شده بر اساس ویژگی<sup>۵</sup> ارائه کردند که رفتار بازنشر پست‌ها را بر اساس تعداد بازنشرهای بالقوه، مدل‌سازی می‌کند. برخلاف کارهای دیگر، این کار یک عمل کلاس‌بندی چندگانه<sup>۶</sup> است که در آن یک پست، در یکی از چهار کلاس ممکن جای می‌گیرد. کلاس‌ها به شکل کلاس صفر، پست‌های بازنشر نشده، کلاس یک، پست‌های با کمتر از ده بار بازنشر، کلاس دو، پست‌های با کم‌تر از ۱۰۰ بار بازنشر و کلاس سه، پست‌های با بیش از ۱۰۰ بار بازنشر، می‌باشند. مدل

مربوط به محتوای یک پست، به تنهایی دارای اطلاعات کافی برای مدل‌سازی رفتار بازنشر کاربران نیستند. این نکته در [۷] نیز، مورد تأیید قرار گرفت.

در یک مطالعه‌ی مشابه [۶]، یک کار تجربی برای پیش‌بینی تصمیم‌بازنشر یک پست انجام شد. در این پژوهش، یک الگوریتم مبتنی بر یادگیری برخط برای پیش‌بینی تا حد ممکن سریع، توسعه داده شد [۸ و ۹]. سپس، برای مرحله آموزش مدل‌های ارائه شده، از زیرمجموعه‌های مختلف داده که بر اساس زمان و روز تولید شده بود، استفاده کردند تا از اطلاعات زمانی پست‌ها برای پیش‌بینی بازنشر یک پست، بهتر بهره ببرند. در این پژوهش، همانند مطالعه‌ی [۱۰]، دلیل استفاده از این مدل، به صراحت بیان نشده است و مدل با استفاده از مجموعه داده‌های مختلف، مورد ارزیابی قرار نگرفته است. در این پژوهش، عملکرد روش یادگیری برخط، با پیش‌بینی‌های انسانی مقایسه شده و ادعا شده است که این روش، به خوبی پیش‌بینی‌های انسانی عمل می‌کند. زمان و همکارانش در [۱۱] نیز، پژوهشی در ارتباط با مدل‌سازی رفتار بازنشر کاربران بر اساس روش تصفیه همکارانه انجام دادند. برخلاف مطالعات دیگر که از ویژگی‌های مستقیماً استخراج شده از پست‌ها یا کاربران استفاده می‌کنند، آن‌ها از بازخورد مثبت و منفی غیرمستقیم در مدلسازان استفاده کردند. اگر کاربران پیگیری‌کننده فعال، یک پست را بازنشر کنند، به عنوان بازخورد مثبت و در غیر این صورت به عنوان بازخورد منفی در نظر گرفته می‌شود. اما یک عیب پژوهش، این است که آن‌ها مدل‌های خود را بر اساس حداقل یک ساعت داده‌ی پس از انتشار یک پست آموزش دادند. از سوی دیگر، مطالعات قبلی نشان می‌دهند که بیشتر از نود درصد پست‌های بازنشر شده، در اولین ساعت پس از ایجاد، اتفاق می‌افتند. بنابراین، آموزش یک مدل بر اساس چنین بازه‌ی زمانی طولانی از نظر عملی ارزشمند نیست. آرتزی و همکارانش در [۱۲]، یک مدل متمایزکننده<sup>۱</sup>، برای مدل‌سازی احتمالاتی رفتار بازنشر یک کاربر، توسعه دادند. آن‌ها چندین ویژگی تاریخچه‌ای و لغوی از متن پست و برخی ویژگی‌هایی از کاربر انتشاردهنده پست‌ها، استخراج کردند. آن‌ها برای مدل‌سازی از دو طبقه بندی مختلف به نام درخت رگرسیون تجمیعی چندگانه

<sup>4</sup> Feature Based

<sup>5</sup> Feature weighted model

<sup>6</sup> Multiple classification

<sup>1</sup> Discriminative

<sup>2</sup> Latent Dirichlet Allocation

<sup>3</sup> Bayesian Network

سهم هر تک ویژگی را در پیش‌بینی تصمیم بازنشر پست‌ها مطالعه می‌کنیم. همچنین چند ویژگی جدید معرفی کرده‌ایم که در کارهای قبلی استفاده نشده‌اند.

### ۳- مفاهیم اولیه روش پیشنهادی

به منظور ارائه روش پیشنهادی برای مدل‌سازی رفتار بازنشر کاربران، در ابتدا به ارائه مقدماتی در خصوص مفاهیم به کار رفته در روش پیشنهادی پرداخته شده است.

#### ۳-۱ اتوماتای یادگیر

اتوماتای یادگیر ( $LA$ )، نوعی از واحد تصمیم‌گیری است که تلاش می‌کند اقدام بهینه را از بین یک مجموعه اقدامات ممکن، از طریق تعامل با محیط ناشناخته و تصادفی، انتخاب کند. در هر تکرار، هر  $LA$  یک اقدام را بر اساس توزیع احتمالات اقدامات خود انتخاب می‌کند و آن را به سمت محیط تصادفی می‌فرستد. محیط تصادفی با ارزیابی اقدام انتخابی، یک پاسخ تصادفی به  $LA$  تولید می‌نماید. به این پاسخ تصادفی، سیگنال تقویتی اطلاق می‌گردد. سپس  $LA$ ، توزیع احتمالات اقدامات خود را با استفاده از سیگنال تقویتی و یک الگوریتم یادگیر، به‌روزرسانی می‌نماید. این روش کاربردهای زیادی در مسائل بهینه‌سازی دارد.

در اتوماتای یادگیر، محیط را می‌توان به کمک سه تایی  $E = \{\alpha, \beta, c\}$  نمایش داد، که در این سه تایی  $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_r\}$ ، نشان‌دهنده مجموعه متناهی از اقدامات ممکن برای هر اتوماتا می‌باشد،  $\beta = \{\beta_1, \beta_2, \dots, \beta_m\}$  نشان‌دهنده مجموعه مقادیر سیگنال تقویتی است و  $c = \{c_1, c_2, \dots, c_r\}$  جهت نشان دادن مجموعه احتمالات جریمه (پنالتی) به کار می‌رود. هر  $c_i$  متناظر بر اقدام  $\alpha_i$  می‌باشد. بر اساس احتمالات جریمه محیط، به دودسته ثابت و متغیر با زمان تقسیم می‌گردد. در صورتی که این احتمالات در محیط تصادفی ثابت باشند، محیط ایستا<sup>۶</sup> نامیده می‌شود و در صورتی که با تغییر زمان، تغییر کنند، محیط غیر ایستا<sup>۷</sup> می‌باشد.

همچنین محیط تصادفی بر اساس مقادیر سیگنال تقویتی به سه دسته  $P$ ،  $Q$  و  $S$  تقسیم می‌شود. سیگنال تقویتی در محیط‌های تصادفی P-Model به صورت  $\{0,1\}$  می‌باشد، و در محیط‌های Q-Model به صورت مقادیر مشخص بین

استخراج ویژگی آن‌ها، مجموعه‌ای از ویژگی‌ها را از خود پست و از کاربر منتشرکننده پست استخراج می‌کند. برخلاف [۱۲] تمرکز آن‌ها بیشتر بر روی ویژگی‌های اجتماعی است. آن‌ها از یک جداکننده<sup>۱</sup> ماشین بردار پشتیبان<sup>۲</sup> با هسته‌ی Radial Basis Function (RBF) استفاده کردند که مدل آن‌ها را قادر می‌سازد، مرزهای پیچیده‌ای برای تفکیک کلاس‌ها به وجود آورد. روش آن‌ها که بر اساس وزن‌دهی بنا شده است، یک وزن به هر ویژگی اختصاص می‌دهد، که بر اساس بهره اطلاعات<sup>۳</sup> هر ویژگی، محاسبه می‌شود. این روش به هر ویژگی که بهره اطلاعاتی بیشتری داشته باشد، وزن بالاتری اختصاص می‌دهد. این نوع وزن‌دهی به ویژگی‌ها، سبب می‌شود این ویژگی‌ها سهم بیشتری در عمل کلاس‌بندی داشته باشند. مقادیر وزن بر اساس یک ارزیابی آزمایشی بر روی مجموعه داده، به دست آمده است. هرچند گزارش شده است که روش آن‌ها از روش‌های بدون استفاده از وزن‌دهی بهتر عمل می‌کند، نویسندگان مدارک کافی ارائه نکرده‌اند تا نشان دهند این روش برای مجموعه داده‌های دیگر و با تنظیمات دیگر نیز، بهینه است. یک تحقیق مشابه برای مدل‌سازی رفتار بازنشر کاربران توسط هونگ و همکاران<sup>۴</sup> [۱۹]، انجام گرفت. آن‌ها این عمل را بنا بر دو مسئله‌ی کلاس‌بندی دودویی و چندگانه<sup>۵</sup> تنظیم کردند. هدف عمل کلاس‌بندی دودویی این است که، مشخص کند یک پیام بازنشر خواهد شد یا خیر، و عمل کلاس‌بندی چندگانه سعی می‌کند حجم بازنشرهای یک پست را پس از انتشار آن پیش‌بینی کند. آن‌ها از روش TF-IDF برای پردازش ویژگی‌های محتوا استفاده کردند. ولی مشخص نکردند دقیقاً از چه رده‌بندی استفاده کرده‌اند و کدام ویژگی‌ها بیشتر در عمل کلاس‌بندی مشارکت داشته است. همچنین روش آن‌ها از نظر عمومیت نیز مشکل دارد، چرا که بر روی مجموعه داده‌ی محدودی آزمایش شده است.

بیشتر کار انجام گرفته در خصوص مدل‌سازی رفتار بازنشر کاربران، روی یک مجموعه داده‌ی محدود با تنظیمات محدود انجام گرفته است. بنابر اطلاعات ما هیچ تحقیقی انجام نشده است که سهم هر ویژگی را به‌تنهایی در پیش‌بینی تصمیم بازنشر بررسی کند. در این تحقیق ما

<sup>5</sup> Binary and multiple classification problem

<sup>6</sup> Stationary

<sup>7</sup> Nonstationary

<sup>1</sup> Classifier

<sup>2</sup> Support Vector Machine

<sup>3</sup> Information gain

<sup>4</sup> Hong et al

$$p(k+1) = T(p(k), \alpha(k), \beta(k)) \quad (3)$$

$T$  یک تابع از میزان کنونی احتمال اقدامها  $(p(k))$ ، اقدام انتخاب شده در لحظه  $k$ ، و سیگنال تقویتی محیط (پاسخ محیط) به اقدام انتخاب شده  $(\beta(k))$  می باشد. به دلیل اینکه  $p(k+1)$  به مقادیر  $\alpha(k)$  و  $\beta(k)$  که به صورت تصادفی هستند، وابسته است مقدار  $p(k+1)$  نیز یک کمیت تصادفی می باشد. بنابراین، یک مجموعه تصادفی  $\{p(k), k=0,1,2,\dots\}$  یک فرآیند تصادفی است که تکامل آن به وسیله این الگوریتم یادگیری اداره می گردد. همان طور که پیشتر اشاره شد، در محیط های P-model (محیط مسئله با دو خروجی باز نشر و عدم باز نشر) الگوریتم یادگیری بر اساس روابط (۴) و (۵) می باشد.

الف- پاسخ مطلوب از محیط (عمل باز نشر)  $\beta(n)=1$

$$\begin{aligned} p_i(n+1) &= p_i(n) + a[1 - p_i(n)] \\ p_j(n+1) &= (1-a)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad (4)$$

ب- پاسخ نامطلوب از محیط (عدم باز نشر)  $\beta(n)=0$

$$\begin{aligned} p_i(n+1) &= (1-b)p_i(n) \\ p_j(n+1) &= \frac{b}{r-1} + (1-b)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad (5)$$

در رابطه (۴) و (۵)،  $a$  پارامتر پاداش و  $b$  پارامتر جریمه می باشد. اگر  $a$  و  $b$  با هم برابر باشند، الگوریتم را  $L_{RP}^3$  می نامیم. اگر  $b$  از  $a$  خیلی کوچک تر باشد، الگوریتم را  $L_{RE}^4$  می نامیم. اگر مقدار  $b$ ، صفر در نظر گرفته شود، الگوریتم را  $L_{RI}^5$  می نامند. در این نوع الگوریتم به اقداماتی که منجر به پاسخ نامطلوب از محیط می گردد جریمه تعلق نمی گیرد ولی اقدامات منجر به پاسخ مطلوب پاداش دریافت می کنند.

### ۳-۲ آنتروپی

برای اطلاع از همگرایی اتوماتای یادگیر از مفهوم آنتروپی استفاده می شود. آنتروپی معیاری است برای اندازه گیری میزان اطلاعاتی که توسط یک منبع تولید می شود و یا توسط فرد شاهد<sup>۶</sup> دریافت می گردد. این ایده در ابتدا توسط شانون<sup>۷</sup> در سال ۱۹۴۸ ارائه شد. آنتروپی در نظریه اطلاعات، معیار عددی از میزان اطلاعات یا میزان تصادفی بودن یک متغیر تصادفی است. در واقع آنتروپی یک متغیر تصادفی،

$[0,1]$  است و در S-Model، مقادیر پیوسته تصادفی می باشد.

یک اتوماتای یادگیر بر اساس اقدامات ممکن به دو کلاس عمده  $FALA^1$  و  $CALA^2$  تقسیم بندی می شود. در  $FALA$ ، مجموعه اقدامات متناهی بوده و توزیع احتمالات اقدامات یک  $FALA$  با  $r$  اقدام، به صورت توزیع احتمالات  $r$  بعدی می باشد. برخلاف  $FALA$ ، در  $CALA$  اقدامات ممکن مقادیر واقعی بوده و تابع توزیع احتمالات، برای احتمال اقدامات استفاده می شود.

به صورت رسمی، یک اتوماتای یادگیر از نوع  $FALA$  به صورت یک چهارگانه  $(\alpha, \beta, T, p(k))$  تعریف می گردد که  $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_r\}$ ، یک مجموعه متناهی از اقدامات است،  $\beta$  یک مجموعه از ورودی ها (یا سیگنال های تقویتی) به اتوماتا می باشد و  $T$  یک الگوریتم یادگیری برای به روزرسانی احتمال اقدامات می باشد.  $p(k)$  یک بردار احتمال اقدامات در لحظه  $k$  می باشد که به صورت رابطه (۱) است.

$$p(k) = [p_1(k), p_2(k), \dots, p_r(k)]^T \quad (1)$$

در شکل (۱) بلاک دباگرام اتوماتای یادگیر تصادفی نشان داده شده است.



شکل ۱- اتوماتای یادگیر تصادفی

مقدار احتمال هر اقدام  $\alpha_i$  در لحظه  $k$  همواره بزرگ تر یا مساوی صفر  $(p_i(k) \geq 0, \forall i, k)$  است و جمع احتمالات هر یک از اقدامها در لحظه  $k$  برابر یک می باشد (  $\sum_{i=1}^r p_i(k) = 1, \forall k, k=0,1,2,\dots$  بنا به تعریف به صورت رابطه (۲) است:

$$p_i(k) = \Pr[\alpha(k) = \alpha_i | p(k)], i=1, \dots, r. \quad (2)$$

در حالت کلی الگوریتم یادگیری برای به روزرسانی  $p(k)$  در رابطه (۳) آمده است:

<sup>5</sup> Linear Reward Inaction

<sup>6</sup> Observer

<sup>7</sup> Shannon

<sup>1</sup> Finite Action-Set Learning Automata

<sup>2</sup> Continues Action-Set Learning Automata

<sup>3</sup> Linear Reward Penalty

<sup>4</sup> Linear Reward Epsilon Penalty

$$P = \{p_1 \dots p_n\} \quad (۹)$$

$$\text{repost}(u, v, p, t') = \{0, 1\} \quad (۱۰)$$

$$(t' > t)$$

روش پیشنهادی دارای دو بخش بسیار کلیدی می باشد.

- شناسایی متغیرهای مؤثر در مدل سازی رفتار بازنشر
  - ارائه روش پیش بینی رفتار بازنشر بر اساس متغیرهای مدل
- در ادامه به این دو بخش به صورت مجزا پرداخته خواهد شد.

#### ۴-۱ متغیرهای مؤثر در مدل سازی رفتار بازنشر

عمده متغیرهای پیشنهادی در سه دسته، محتوای پست و قدرت ارتباطی بین کاربران و ویژگی های پست، در نظر گرفته شده است. در انتخاب این سه دسته، علاوه بر توجه به ماهیت مسئله (مدل سازی رفتار بازنشر)، ویژگی امکان پذیری برای عملیات در محیط برخط نیز در نظر گرفته شده است.

یکی از اصلی ترین متغیرهای مدل سازی رفتار بازنشر، محتوای پست می باشد. هر پست دارای محتوایی است که کاربر بعد از مطالعه این محتوا، نسبت به بازنشر آن تصمیم می گیرد. به منظور بررسی محتوای یک پست و اثر آن در تصمیم بازنشر، بایستی به میزان نزدیکی این محتوا با علائق کاربر توجه کرد. هرچه پست به لحاظ محتوا، نزدیکی بیشتری با علائق کاربر داشته باشد، احتمال بازنشر آن نیز افزایش می یابد [۲۰]. برای یافتن علائق کاربر، از پست هایی که کاربر قبلاً نشر (یا بازنشر) داده است، استفاده می گردد. هرچه میزان شباهت پست مورد نظر به پست های نشر (یا بازنشر) شده کاربر زیاد باشد، احتمال بازنشر بالاتری خواهد داشت [۲۰ و ۲۱].

برای تعیین میزان شباهت یک پست مانند  $p$ ، با مجموعه پست های کاربر  $u$  از مجموعه کاربران  $V$ ، تا زمان  $t'$  بردار ویژگی پست های کاربر  $u$  محاسبه گردد. برای این کار در گام اول بایستی کلیه کلمات از کلیه پست های منتشر شده توسط کاربر تا زمان حاضر  $t$  استخراج شود و در گام دوم مقادیر عددی به بردار بر اساس حضور کلمات در متن منتسب گردد [۲۲]. یکی از روش های پرکاربرد این کار  $tf.idf$  می باشد، که بر اساس فراوان عبارت و معکوس فراوانی سند اقدام به تبدیل متن

امید ریاضی میزان اطلاعات حاصل از مشاهده آن است. آنتروپی متغیر تصادفی گسسته  $X$ ، با تابع جرم احتمال  $P(X)$ ، با نماد  $H(X)$  نمایش داده می شود و طبق رابطه (۶) تعریف می گردد.

اطلاعات حاصل از مشاهده یک رویداد برابر با منفی لگاریتم احتمال رخ دادن آن تعریف می شود. اطلاعات حاصل از مشاهده یک رویداد قطعی (یعنی با احتمال یک) صفر است. در رابطه (۷)،  $p(x_i)$  میزان احتمال متغیر تصادفی  $X$  در لحظه  $t$  می باشد.

$$H(X) = \sum_{i=0}^{n-1} p(x_i) \log_b (1/p(x_i)) \quad (۶)$$

$$p(x_i) = \text{prob}\{X_i = a_i\} \quad (۷)$$

پارامتر  $b$  می تواند مقادیری مانند  $b = 2.71828 \dots$  یا  $b = 10$  را اختیار کند.

در روش اتوماتای یادگیر، آنتروپی می تواند به عنوان معیاری برای سنجش میزان کارایی سیستم به کار رود. آنتروپی هر محیط، مقدار عدم قطعیت آن را نشان می دهد. هرچه محیط تصادفی تر باشد مقدار آن افزایش می یابد، و هرچه کمتر تصادفی باشد مقدار آن کاهش می یابد. بدین صورت که وقتی محیط قادر باشند که عمل بهینه را بیابند، آنتروپی اتوماتاها و به طبع آن آنتروپی محیط کاهش می یابد.

#### ۴- روش پیشنهادی

هر اجتماع برخط را می توان به صورت یک گراف مطابق رابطه (۸) نشان داد.  $V$  نشان دهنده رئوس گراف برای نمایش کاربران و  $E$  نشان دهنده ارتباطات بین کاربران می باشند. در اجتماعات برخط، پست ها به صورت مجموعه  $P$  مطابق رابطه (۹) از طریق ارتباطات بین کاربران منتقل می گردند. پست  $p$  توسط کاربر  $v$  در زمان  $t$  ایجاد می گردد. هر کاربر  $u$  بعد از مشاهده پست  $p$  اقدام به اخذ تصمیم بازنشر در زمان  $t'$  می نماید. هر رفتار بازنشر برای هر کاربر در زمان  $t'$  به صورت رابطه (۱۰) مدل می گردد. یک زمانی است که کاربر  $u$  اقدام به بازنشر پست  $p$  در زمان  $t'$  می نماید و صفر زمانی است که این کاربر، از بازنشر این پست امتناع می کند. هدف مسئله، مدل سازی رفتار بازنشر کاربران به منظور پیش بینی تصمیم بازنشر آن ها می باشد.

$$G = (V, E)$$

$$V = \{u_1 \dots u_n\} \quad (۸)$$

$$E = \{(u, v) | v, u \in V\}$$



در  $d_p \cdot d_q - |d_p| + |d_q|$  برابر با تعداد کلماتی است که در  $d_1$  یا در  $d_2$  و یا هر دو رخ می‌دهد.

$$Jaccard(d_p, d_q) = \frac{|d_p \cap d_q|}{|d_p \cup d_q|} \equiv \frac{d_p \cdot d_q}{|d_p| + |d_q| - d_p \cdot d_q} \quad (13)$$

#### شباهت به روش دایس:

از دیگر روش‌های تعیین شباهت یک پست با پست‌های قبلی کاربر می‌توان به روش سورنسون-دایس<sup>۱</sup> اشاره کرد که به اختصار در منابع به روش دایس مشهور است. برخلاف روش‌های دیگر که بر اساس فاصله بین دو بردار عمل می‌کنند، روش دایس برای تعیین میزان شباهت، تنها تعداد کلمات مشترک و تعداد کلمات غیرمشترک را در نظر می‌گیرد. رابطه (۱۴) روش محاسبه این معیار را نشان می‌دهد.

$$Dice = \frac{2|d_p \cap d_q|}{|d_p| + |d_q|} \equiv \frac{2 \times (d_p \cdot d_q)}{|d_p| + |d_q|} \quad (14)$$

در این رابطه،  $|d_p \cap d_q|$ ، برابر تعداد کلمات مشترک دو بردار است و  $|d_p|$  تعداد کلمات با فرکانس غیر صفر در مجموعه پست‌های کاربر و  $|d_q|$  تعداد کلمات با فرکانس غیر صفر در پست مورد بررسی، می‌باشند. مخرج رابطه (۴) به نوعی نقش نرمال‌سازی را ایفا می‌نماید.

#### شباهت به روش همپوشانی:

روش همپوشانی یک روش دیگر اندازه‌گیری شباهت است که همپوشانی بین دو مجموعه محدود را اندازه‌گیری می‌کند. همان‌طور که در رابطه (۱۵) مشاهده می‌شود، مقدار این شباهت با اندازه اشتراک دو بردار، تقسیم بر اندازه بردار کوچک‌تر بین دو بردار، برابر است.

$$Overlap = \frac{|d_p \cap d_q|}{\min(|d_p|, |d_q|)} \equiv \frac{d_p \cdot d_q}{\min(|d_p|, |d_q|)} \quad (15)$$

اگر  $d_q$  یک زیرمجموعه از  $d_p$  باشد، ضریب همپوشان با یک برابر است.

هیچ‌کدام از روش‌های فوق برای تعیین میزان شباهت، در همه کاربردها بهینه عمل نمی‌کنند. با توجه به ماهیت مسئله و تنوع کاربران و پست‌ها نیاز است که از روش‌های مختلف تعیین شباهت، به‌صورت هم‌زمان استفاده گردد.

(پست‌های کاربران) به بردار ویژگی می‌نماید [۲۳]. روش محاسبه  $tf.idf_{i,j}$  برای کلمه  $j$  در مستند  $i$  در رابطه (۱۱) نشان داده شده است.

$$TF \cdot IDF_{i,j} = TF_{i,j} \times IDF_j \quad (11)$$

$$= \frac{n_{i,j}}{\sum_{k=1}^N n_{i,k}} \log\left(\frac{N}{|\{i: t_j \in d_i\}| + 1}\right)$$

در رابطه (۱) در بخش  $tf$ ،  $n_{i,j}$  مربوط به تعداد تکرار کلمه  $j$  در پست  $i$  و  $\sum_{k=1}^N n_{i,k}$  مربوط به جمع تکرار همه کلمات در پست  $i$  می‌باشد. در بخش  $IDF$ ،  $N$  تعداد کل پست‌ها و  $|\{i: t_j \in d_i\}|$  تعداد پست‌های است، که حاوی کلمه  $t_j$  می‌باشند. به‌منظور رفع مشکل مخرج صفر، با یک جمع شده است [۲۲].

برای تصمیم‌گیری بر اساس محتوای پست در عمده کارهای مرتبط [۱۰ و ۲۰ و ۲۱ و ۲۴ و ۲۵] از روش‌های مختلف اندازه‌گیری شباهت استفاده شده است، که در ادامه به بررسی هر یک از آن‌ها می‌پردازیم. برای تعیین میزان شباهت بین  $d_p$  بردار پست و  $d_q$  بردار پست‌های ایجادشده توسط کاربر  $u$  تا زمان  $t$  از روش‌های زیر استفاده می‌گردد.

#### شباهت به روش کسینوس بردار:

میزان شباهت بین این دو بردار بر اساس کسینوس زاویه بین این دو بردار محاسبه می‌گردد. روش محاسبه این معیار شباهت در رابطه (۱۲) آمده است.

$$\cos(d_1, d_2) = \frac{|d_p \cap d_q|}{|d_p| \times |d_q|} \equiv \frac{d_p \cdot d_q}{|d_p| |d_q|} \quad (12)$$

ضرب داخلی بیان‌کننده زاویه بین دو بردار است. اگر حاصل این عبارت یک باشد، زاویه صفر درجه است و بیشترین تطابق را از نظر شباهت بین دو بردار وجود دارد. اگر حاصل صفر باشد، زاویه بین آن دو بردار ۹۰ درجه می‌باشد و کم‌ترین میزان شباهت را دارا می‌باشند.

#### شباهت به روش جاکارد:

میزان شباهت دو بردار با استفاده از روش جاکارد، برابر با میزان اشتراک این دو بردار تقسیم بر اجتماع این دو بردار است که در رابطه (۱۳) مشاهده می‌شود. در این رابطه،  $|d_p \cap d_q|$ ، برابر تعداد کلمات مشترک دو بردار است و

<sup>۱</sup> Sorensen-Dice

$$LST = rep_v \times Inf(u, v), v \in adj(u) \quad (18)$$

**تازگی<sup>۲</sup> پست:** با توجه به ارتباطات گسترده بین کاربران در اجتماعات برخط، یک پست در طیف وسیعی از کاربران به سرعت انتقال پیدا می کند. این امر باعث شده پست ها با گذشت زمان، اثرگذاری خود را از دست بدهند. هر چه از زمان ایجاد یک پست می گذرد، احتمال اثرگذاری آن و در نتیجه احتمال رخداد رفتار بازنشر کاربر در مواجهه با آن، کاسته خواهد شد. در اکثر پژوهش های صورت گرفته در حوزه مسئله، گذشت زمان دارای نسبت عکس با احتمال بازنشر یک پست در نظر گرفته شده است [۲۹-۳۲]. طریقه محاسبه معیار زمان، در رابطه (۱۹) نشان داده شده است. در رابطه (۹)، زمان ایجاد پست  $t$  و زمان تصمیم برای بازنشر  $t'$  می باشد. ضرایب  $a$  و  $b$ ، مربوط به دارا بودن هشتگ و آدرس پیوند می باشند. همان طور که در پیشینه تحقیق اشاره شد، یک پست در صورت داشتن هشتگ و یا آدرس پیوند، احتمال بازنشر بیشتری دارد [۳۳-۳۵]. در صورتی که یک پست دارای هشتگ و یا آدرس پیوند باشد مقادیر این ضرایب برابر با دو خواهد بود و در غیر این صورت یک می باشد. همان طور که ملاحظه می شود، این معیار با گذشت زمان به سرعت کوچک خواهد شد.

$$PF = \frac{a \times b}{(t' - t) + a + b} \quad (19)$$

هر یک از متغیرهای ذکر شده در مدل سازی رفتار بازنشر یک کاربر، مؤثر می باشند. در روش پیشنهادی این مقاله، بر روی قابلیت عملیاتی روش تأکید اساسی شده است. به همین جهت روش های پیشنهادی برای اندازه گیری این متغیرها، فاقد پیچیدگی محاسباتی و سربار زمانی می باشند. با توجه به ماهیت تصادفی محیط اجتماعات برخط و انواع مختلف کاربران، میزان تأثیر هر یک از این معیارها برای کاربران مختلف متفاوت است.

#### ۴-۲- ارائه روش پیش بینی بر اساس متغیرهای مدل سازی رفتار بازنشر

در ادامه این بخش، روش پیشنهادی برای یادگیری مدل رفتار بازنشر کاربران بر اساس متغیرهای ذکر شده، تشریح می گردد.

به منظور پیش بینی رفتار بازنشر پست  $p$  توسط کاربر  $u$  در زمان  $t'$ ، شش معیار مؤثر در این تصمیم بازنشر مشخص

#### قدرت ارتباطی:

ارتباطات بین کاربران در اجتماعات برخط، اغلب به صورت پیگیری<sup>۱</sup> می باشند. هر کاربر بر اساس علاقه خود، می تواند کاربران دیگر را پیگیری نماید و از تمام پست های منتشر شده این کاربران مطلع گردد. هر ارتباط به صورت یک زوج مرتب  $(u, v)$  نشان داده می شود. بنا به قرارداد  $(u, v)$ ، نشان می دهد که کاربر  $v$ ، کلیه پست های کاربر  $u$  را پیگیری می نماید. بنا به تعریف ارائه شده در [۲۶]، نفوذ کاربر  $u$  بر کاربر  $v$ ، میزان احتمال بازنشر پست های کاربر  $u$ ، توسط کاربر  $v$  می باشد. به بیان دیگر، هنگامی که یک رخداد بازنشر اتفاق می افتد، یک مورد موفق از تأثیر کاربر  $u$  بر کاربر  $v$  در نظر گرفته می شود. هر تلاش، یعنی هر پست نوشته شده توسط  $u$  می تواند به عنوان یک دنباله برنولی بررسی شود. احتمال موفقیت، نسبت تعداد تلاش های موفق بر کل تعداد تلاش ها است. از این رو، احتمال نفوذ  $v$  در  $u$  بر اساس رابطه (۱۶) برآورد شده است:

$$\inf(u, v) = \frac{|\{p \in P | \exists t' \in T : repost(v, u, p, t')\}|}{|\{p \in P | \exists t \in T : post(v, u, p, t)\}|} \quad (16)$$

از طرف دیگر میزان شهرت کاربر  $u$  در قدرت ارتباطی آن با کاربر  $v$  تأثیرگذار است [۲۷ و ۲۸]. برای محاسبه میزان شهرت هر کاربر، روش ساده و مؤثری در رابطه (۱۷) پیشنهاد شده است. در این رابطه  $f_v$  نشان دهنده تعداد دنبال کنندگان کاربر  $v$  و  $g_v$  نشان دهنده تعداد کاربرانی است که کاربر  $u$  آن ها را پیگیری می نماید. هر چه نسبت این دو مقدار به هم زیاد باشد، نشان دهنده اعتبار و شهرت کاربر می باشد. به عبارت ساده تر، هر چه نسبت پیگیری کنندگان به پیگیری شوندگان بیشتر باشد، نشان از شهرت و مرجعیت این کاربر، دارد.

$$rep_v = \frac{f_v}{g_v + f_v} \quad (17)$$

همان طور که در رابطه (۱۸) مشاهده می شود، قدرت ارتباطی، با میزان شهرت کاربر و میزان نفوذ کاربر بر کاربر نسبت مستقیم دارد. قدرت هر ارتباط بین کاربر  $u$  و کاربران مجاور  $(adj(u))$  مانند  $v$ ، به مقدار دو مفهوم اعتبار و نفوذ بستگی دارد. این متغیر مقادیر بین صفر تا یک دارد و مقادیر نزدیک تر به یک، نشان دهنده قدرت ارتباطی بالاتر بین دو کاربر می باشد.

<sup>2</sup> Freshness

<sup>1</sup> Follow



همان طور که در رابطه (۲۲) نشان داده شده است، بر اساس مقادیر  $x_i$  ورودی و ضرایب، تابع طبقه‌بند  $\gamma$  ساخته می‌شود. بعد از ساخت طبقه‌بند، برای هر نمونه از پست‌ها در صورتی که مقدار  $\gamma$  مطابق رابطه (۲۴) محاسبه شود و بیشتر از صفر باشد، سامانه بازنشر این پست را پیش‌بینی می‌نماید و در صورتی که برای یک پستی این مقدار اگر کمتر از صفر باشد، سامانه رفتار عدم بازنشر برای این پست را پیش‌بینی می‌نماید.

جدول ۱- متغیرهای شناسایی شده برای مدل‌سازی رفتار

بازنشر کاربران

معیار	نماد	وزن (ضریب)
شبهات به روش کسینوس	$x_1$	$W_1$
شبهات به روش جاکارد	$x_2$	$W_2$
شبهات به روش دایس	$x_3$	$W_3$
شبهات به روش هم‌پوشانی	$x_4$	$W_4$
قدرت ارتباطی	$x_5$	$W_5$
تازگی پست	$x_6$	$W_6$
اریبی	-	$W_0$

مقادیر مربوط به وزن (ضرائب) این متغیرها و مقدار اریبی باید توسط یک روش یادگیری تعیین گردد. در این مقاله از روش یادگیری مبتنی بر تیمی از اتوماتاهای یادگیر استفاده شده است.

۴-۲-۱- تعیین ضرائب مربوط به متغیرهای مدل‌سازی توسط تیمی از اتوماتای یادگیر

یک بازی زمانی اتفاق می‌افتد که  $n$  بازیگر در یک بازی درگیر هستند، به صورتی که هر بازی یک مجموعه‌ای از اقدام‌ها برای انتخاب کردن در اختیار دارد. برای هر دور از بازی، هر یک از بازیگران یک اقدام به‌خصوص از بین مجموعه اقدام‌های ممکن برای خود انتخاب می‌کند. بعد از آن، هر بازیگر از محیط یک سود دریافت می‌کند که این سودها کاملاً تصادفی است. به خاطر اینکه این بازی از نوع عقلانیت محدود (اطلاعات ناقص) می‌باشد، هیچ‌کدام از بازیگران هیچ اطلاعی از احتمال دریافت پاداش در قبال هیچ‌کدام از اقدام‌های خود ندارند. مسئله اصلی پیدا کردن اقدام‌های بهینه برای بازیگران با توجه به سود است. به این نکته دقت کنید که این می‌تواند به معنی سود غیر مساوی یا مشترک برای بازیگران مختلف باشد. هر بازیگر به صورت یک اتوماتا نشان داده می‌شود، و اقدام‌های هر بازیگر همان

گردید. برای حل مسئله پیش‌بینی رفتار بازنشر، یک مسئله طبقه‌بندی دو کلاسی (بازنشر یا عدم بازنشر) تعریف می‌گردد. در این گونه مسائل تابع هدف به صورت  $t \in \{0,1\}$  می‌باشد که مقدار  $t=0$  برای کلاس  $C_1$  (عدم بازنشر) و مقدار  $t=1$  برای کلاس  $C_2$  (بازنشر) استفاده می‌گردد. مطابق رابطه (۲۰) از تابع فعال‌ساز<sup>۱</sup> خطی برای طبقه‌بندی استفاده می‌گردد.

$$y(x) = f(W^T x + W_0) \quad (20)$$

در رابطه (۲۰)،  $W_0$  مقدار اریبی<sup>۲</sup> خوانده می‌شود. در آمار، اریبی یک تخمین‌گر<sup>۳</sup>، همان اختلاف بین امید ریاضی تخمین‌گر و مقدار واقعی پارامتر تخمین زده شده می‌باشد. تخمین‌گر یا قانون تصمیم‌گیری با بایاس صفر را «ناریب» و در غیر این صورت «اریب» می‌گویند. به بیان ریاضی، فرض کنید داده  $x_i$  بر اساس توزیع  $P(x|\theta)$  توزیع شده باشد و  $\theta$  یک تخمین بر اساس داده‌های مشاهده شده باشد، اریبی  $\theta$  به صورت رابطه (۲۱) تعریف می‌شود. در این رابطه  $E$  امید ریاضی متغیر  $x$  بر اساس توزیع  $P(x|\theta)$  می‌باشد. مقدار اریبی در این مسئله بر اساس روش یادگیری برخط تعیین می‌گردد.

$$Bias[\hat{\theta}] = E[\hat{\theta}] - \theta \quad (21)$$

به منظور ساخت یک طبقه‌بند بر اساس این شش متغیر و یک مقدار اریبی مطابق روابط (۲۲) و (۲۳) مورد استفاده قرار می‌گیرد. در این رابطه بردار  $x_i$  مربوط به متغیرهای شش‌گانه شناسایی شده است که توضیحات دقیق آن‌ها را در جدول (۱) نشان داده شده است. همین طور  $W_i$  بردار وزن هر یک از متغیرهاست.

$$W_1 x_1 + \dots + W_6 x_6 + W_0 = \sum_{i=1}^6 W_i x_i + W_0 \quad (22)$$

$$y(x) = W^T x + w_0 \quad (23)$$

به عبارت دیگر، تابع طبقه‌بند  $y(x)$ ، تابعی است که بردار  $x$  را به عنوان ورودی دریافت می‌کند و در خروجی مقداری متناسب با طبقه بندی  $\{0,1\}$  را مطابق رابطه (۲۴) تولید می‌کند.

$$\begin{cases} y(x) \geq 0 \rightarrow \text{Assign } x \text{ to } C_1 \\ \text{otherwise} \rightarrow \text{Assign } x \text{ to } C_2 \end{cases} \quad (24)$$

<sup>3</sup> Estimator

<sup>1</sup> Activation Function

<sup>2</sup> Bias

صورت سیگنال تقویتی دریافت می کنند. سیگنال تقویتی محیط  $\beta^i(k)$  برای اتوماتای  $A_i$  برای انتخاب اقدام در نمونه  $k$  می باشد. اگر فرض شود  $\beta^i(k) \in [0,1]$  به ازای  $\forall i, k$  و  $S_i$  مجموعه اقدام های اتوماتای یادگیر  $A_i$  باشد، در این صورت تابع سود  $d^i: \prod_{j=1}^N S_j \rightarrow [0,1]$  برای

$1 \leq i \leq N$  بر اساس رابطه (۲۵) محاسبه می گردد:

$$d^i(x_1, \dots, x_N) = \quad (25)$$

$$E[\beta^i(k) | \alpha^i(k) = x_i, 1 \leq i \leq N]$$

برای هر اتوماتای یادگیر  $A_i$  یک تابع سود به نام  $d^i$  وجود دارد. اساساً، اتوماتاهای یادگیر در این بازی می خواهند سود خود را به حداکثر برسانند. از آنجایی که توابع سود چند گانه وجود دارد، یکی از راه های تعریف هدف یادگیری در اینجا این است که بازی به یک تعادل نش برسد.

**تعریف ۱:** برای  $N$  تایی از  $(a_1, \dots, a_N)$  در صورتی گفته می شود در وضعیت تعادل نش در بازی قرار دارند که برای هر  $i$  ( $1 \leq i \leq N$ ) داشته باشیم (رابطه (۲۶)).

$$d^i(a_1, \dots, a_{i-1}, x, a_{i+1}, \dots, a_N) \leq d^i(a_1, \dots, a_N) \quad \forall x \in S_i \quad (26)$$

در [۳۸] اثبات شده است در صورتی که برای به روز رسانی احتمال انتخاب اقدام ها در هر یک از اتوماتاهای یادگیر از الگوریتم  $L_{RI}$  استفاده شود، تیمی از اتوماتاها قطعاً به تعادل نش خواهد رسید (الگوریتم یادگیری  $L_{RI}$  در انتهای بخش ۳-۲ بحث شد).

گونه خاص دیگری از بازی اتوماتاهای یادگیر که در این مقاله از آن استفاده می شود، وجود دارد که به آن بازی با سود مشترک گفته می شود. در صورتی که همه اتوماتاهای یادگیر بازیگر، فقط یک سود مشترک از محیط دریافت کنند (یعنی  $\beta^i = \beta$ )، این بازی به صورت بازی با سود مشترک خواهد بود. بنابراین، فقط یک سود در این بازی در هر لحظه وجود دارد. به دلیل اینکه فقط از اتوماتاهای یادگیر با اقدام متناهی استفاده می شود می توان  $d$  را به صورت یک ابرماتریس  $D = [d_{j_1 \dots j_N}]$  با ابعاد که یک تا  $N$  در نظر گرفت. اگر  $S = \{\alpha_1^i, \dots, \alpha_{r(i)}^i\}$  یک مجموعه اقدام های اتوماتای  $A_i$ ، در نظر گرفته شود.  $D$  ماتریس احتمال پاداش برای بازی خواهد بود که برای اتوماتاهای یادگیر کاملاً ناشناخته است. هدف این تیم از اتوماتاهای یادگیر بیشینه کردن ارزش مورد انتظار با توجه به سیگنال

مجموعه اقدام های تعریف شده برای هر اتوماتای یادگیر می باشند. بازیگران این بازی اتوماتاهای یادگیر تصادفی از نوع  $FALA$  می باشند. سیگنال تقویتی برای هر اتوماتا به اقدام انتخاب شده توسط همه اتوماتاها بستگی دارد. در هر مرحله از بازی، هر اتوماتا یک اقدام انتخاب می نماید، و محیط با ارزیابی اقدام های انتخابی توسط همه اتوماتاها بازخورد می دهد که به صورت سود (مشابه مباحث نظریه بازی ها) است. بردار احتمالات اقدام ها به صورت یک استراتژی ترکیبی یک بازیگر تعریف می شود که هر یک از اجزای این بردار احتمال مربوط به یک اقدام به خصوص یا استراتژی خالص می باشد.

در مورد یک اتوماتای منفرد، یک سیگنال تقویتی وجود دارد که بایستی اقدام های انتخاب شده آن را بهینه نمایند. در بازی  $LA$  ها، چندین سناریو برای سود وجود دارد، بنابراین، تعداد زیادی تابع لازم است که به صورت هم زمان، سیگنال تقویتی را بیشینه نمایند. هیچ راه مشخصی نیز برای تعیین یک هدف در اختیار نیست. رسیدن به یک مجموعه از نقاط بهینه یکی از راه های تعریف هدف است. این نقاط بهینه مرتبط با سطوح اقدام هایی است که انتظار می رود سیگنال تقویتی را به صورت محلی بیشینه نمایند.

در [۳۶ و ۳۷] یک تعریف رسمی از بازی های  $LA$  ها ارائه شده است، که در این مقاله از بیان آن صرف نظر شده است. همان طور که پیش تر در بخش ۳-۱ به طور خلاصه ذکر شد، یک اتوماتای یادگیر به طور کلی برای یادگیری ارزش بهینه یک متغیر، کافی است. با این حال، برای مشکلات بهینه سازی چند بعدی پیچیده تر، به یک سیستم متشکل از تعدادی اتوماتای یادگیر نیاز است. یک پیکربندی احتمالی برای چنین سیستمی متشکل از اتوماتاهای یادگیر، طراحی بازی اتوماتاهای یادگیر می باشد [۳۶].

اگر  $A_1, A_2, \dots, A_N$  اتوماتاهای درگیر در یک بازی با  $N$  بازیگر باشد. هر مرحله از این بازی، شامل انتخاب اقدام توسط اتوماتاها به عنوان بازیگر و دریافت سود به صورت سیگنال تقویتی از طرف محیط برای این اقدام ها می باشد. اگر  $p_1(k) \dots p_N(k)$  توزیع احتمالی برای  $N$  اتوماتا باشد در هر نمونه  $k$ ، هر یک از اتوماتاهای  $A_i$  یک اقدام  $\alpha^i(k)$  به صورت مستقل و تصادفی بر اساس  $p_i(k)$  ( $1 \leq i \leq N$ ) انتخاب می نمایند. این مجموعه از  $N$  اقدام به صورت ورودی محیط عمل کرده متعاقباً  $N$  سود به صورت تصادفی به

روش را کاهش می‌دهد و زمان رسیدن به همگرایی را افزایش می‌دهد. برای بهبود کارایی روش پیشنهادی، از گسسته‌سازی ضرایب استفاده می‌شود. هدف، یادگیری وزن هر یک از متغیرهای مؤثر در مدل‌سازی رفتار بازنشر کاربران، می‌باشد. برای استفاده از FALA در روش پیشنهادی، بایستی مقادیر پیوسته (وزن‌ها)، به مقادیر گسسته تبدیل گردد. جدول ۲ روش تبدیل مقادیر پیوسته را به گسسته نشان می‌دهد. بازه پیوسته [۰, ۱] به ده منطقه گسسته تبدیل شده است که هر یک از آن‌ها متناظر با یک اقدام از FALA می‌باشند. به عبارت دیگر، برای هر FALA، تعداد ده اقدام متصور است.

همان طور که در جدول ۲ نشان شده است، بازه صفر تا یک به ده بخش مساوی تقسیم شده است. با این کار یک مقدار پیوسته بین صفر تا یک به ده بخش گسسته تقسیم شده است. ذکر این نکته حائز اهمیت است که با این ایده، کارایی سیستم به نحو چشم‌گیری افزایش می‌یابد. بدین صورت که هر یک از FALA ها، ابتدا شروع به انتخاب یک اقدام از بین اقدامات خود می‌نمایند. احتمال اولیه انتخاب هر یک از اقدامات باهم برابر و مساوی  $1/r$  (تعداد اقدامات در اینجا ده) می‌باشد. به این اقدامات، محیط پاسخ می‌دهد. یک پاسخ از محیط دریافت می‌گردد و بازی تیم FALA (ToFALA) به صورت سود مشترک می‌باشد. بر اساس اینکه پاسخ محیط مطلوب باشد یا نامطلوب، هر کدام از FALA ها احتمال اقدامات خود را بر اساس رابطه‌های (۴) و (۵) به روز رسانی می‌نمایند. این تکرار تا زمانی که FALA ها همگرا شوند تکرار می‌شود. همان طور که پیشتر ذکر شد هر اقدام، نماینده بازه‌ای برای ضرایب وزن معیارها است. با هر پاسخ مطلوب محیط، اقدامات انتخاب شده، طبق رابطه (۴) پاداش دریافت می‌نمایند و احتمال انتخاب این اقدام افزایش و احتمال بقیه اقدامات کاهش می‌یابد. به طریقه عکس هم با هر پاسخ نامطلوب محیط، اقدامات، بر اساس رابطه (۵)، جریمه دریافت می‌کنند و مقدار احتمال اقدامات مربوطه کاهش پیدا کرده، بقیه افزایش می‌یابد. وقتی FALA به یک اقدام همگرا شد، یعنی وزن آن متغیر، معادل نماینده دسته مربوط به اقدام می‌باشد (جدول ۲). برای نمونه در صورت که FALA متناظر با معیار شباهت جاکارد به اقدام  $\alpha_2$  همگرا شد، وزن معیار جاکار  $0/3$  در نظر گرفته می‌شود.

محیطی مشترک  $\beta$  است. هر یک از اتوماتاها با توجه اقدام‌های محدود خود بایستی اقدامی انتخاب نمایند که این سود مشترک همیشه بیشینه باشد.

همسایه بر اساس رابطه (۲۷) تعریف می‌گردد.

$$N(a) = \{x \in S' \mid \exists j, x_j = a_j, \forall i \neq j, \text{ and } x_i = a_j\} \quad (27)$$

بنابراین همسایه برای هر  $N$  تایی از اقدامات، یک مجموعه از اقدام‌هاست که فقط در یک اقدام باهم تفاوت دارند. در این صورت یک  $N$  تایی به‌خصوص از اقدام‌ها یک تعادل نش را در بازی با سود مشترک دارا می‌باشند اگر و فقط اگر  $d(a) \geq d(x), \forall x \in N(a)$ . هر جزئی از ماتریس احتمالات پاداش را یک مد از ماتریس می‌نامند. در [۳۸] اثبات شده است که اگر همه اتوماتاهای یادگیر در بازی با سود مشترک از الگوریتم یادگیری LRI (با گام‌های یادگیری کوچک) برای به روز رسانی احتمال اقدامات استفاده نمایند، این تیم از اتوماتاهای یادگیر به طور قطع به یک مد از ماتریس احتمال پاداش همگرا خواهند شد.

جدول ۲- گسسته سازی مقادیر ضرایب متغیرها برای نسبت

دادن به پنج اقدام FALA

اقدام	ضرایب	نماینده دسته
$\alpha_1$	[۰, ۰/۱]	۰/۰۵
$\alpha_2$	[۰/۱, ۰/۲]	۰/۱۵
$\alpha_3$	[۰/۲, ۰/۳]	۰/۲۵
$\alpha_4$	[۰/۳, ۰/۴]	۰/۳۵
$\alpha_5$	[۰/۴, ۰/۵]	۰/۴۵
$\alpha_6$	[۰/۵, ۰/۶]	۰/۵۵
$\alpha_7$	[۰/۶, ۰/۷]	۰/۶۵
$\alpha_8$	[۰/۷, ۰/۸]	۰/۷۵
$\alpha_9$	[۰/۸, ۰/۹]	۰/۸۵
$\alpha_{10}$	[۰/۹, ۱]	۰/۹۵

این مدل از بازی برای بهینه‌سازی یک تابع از  $N$  متغیر (یا پارامتر) حتی در محیط دارای نویز بسیار مناسب است. مجموعه اقدامات هر اتوماتای یادگیر، مجموعه مقادیر ممکن این متغیرها را نشان می‌دهد.

جستجو برای ضرایب متغیرهای مؤثر در مدل‌سازی رفتار بازنشر کاربران، با توجه به پیوسته بودن مقادیر بعضاً کارایی

مجموعه این هفت FALA در یک تیم از FALA ها (ToFALA) در قالب یک بازی با سود مشترک تعریف می‌شود. شکل (۳) نمای کلی از راه حل پیشنهادی را نشان می‌دهد.

### ۵- ارزیابی

در این بخش از مقاله، مجموعه دادگان ارزیابی، معیارهای ارزیابی و نتایج حاصل از ارزیابی ارائه می‌گردد.

#### ۵-۱- مجموعه دادگان

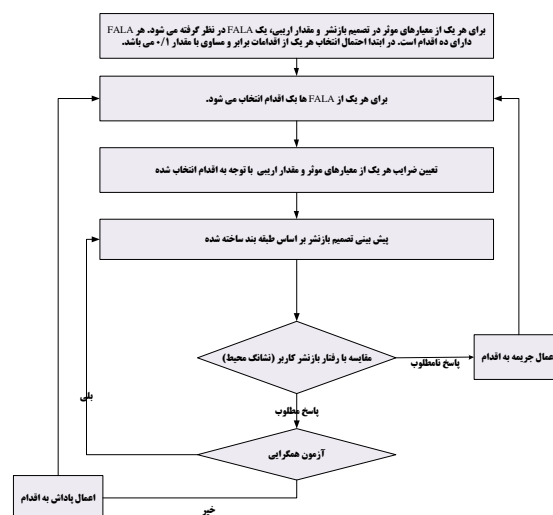
در این بخش، به بیان جزئیات بیشتر، در خصوص مجموعه دادگان استفاده شده در بخش ارزیابی، پرداخته می‌شود. همین‌طور روش جمع‌آوری داده و آماده‌سازی آن تشریح می‌گردد.

با توجه به محبوبیت فراوان سرویس میکرو بلاگ نویسی توئیتر، اغلب پژوهش‌ها، از داده‌های این اجتماع برخط برای ارزیابی استفاده می‌نمایند [۴۰-۴۳]. توئیتر یک تارنمای خدمات میکرو بلاگ نویسی است که در سال ۲۰۰۶ ایجاد شده است. توئیتر به کاربران اجازه می‌دهد، محتوای مورد نظر خود را در قالب پست‌های صد و چهل کاراکتری ایجاد نمایند و این محتوا برای همه کاربران پیگیری‌کننده، قابل مشاهده است. توئیتر محیط مناسبی برای انتشار و تبادل اطلاعات بین کاربران می‌باشد و روزانه در حدود دویست میلیون پست در قالب توئیت بین کاربران، منتقل می‌گردند [۴۴]. مجموعه دادگان توئیتر به دو شیوه، قابل دستیابی است.

الف) استفاده از مجموعه دادگان آماده: این مجموعه دادگان توسط پژوهشگاه‌های مختلف، برای کاربردهای پژوهشی گردآوری شده‌اند و تعداد زیادی از آن‌ها، در اینترنت کاملاً در دسترس است. از مزایای استفاده از این مجموعه دادگان، می‌توان به حجم بالای کاربران، پست‌ها و بازنشرهای جمع‌آوری‌شده، اشاره کرد. در کنار این مزایا، این مجموعه دادگان دارای معایبی نیز می‌باشند. به علت اینکه این مجموعه دادگان برای اهداف خاص پژوهشی گردآوری شده‌اند، بعضاً تمام نیازهای اطلاعاتی و داده‌ای روش دیگر را، پشتیبانی نمی‌کنند.

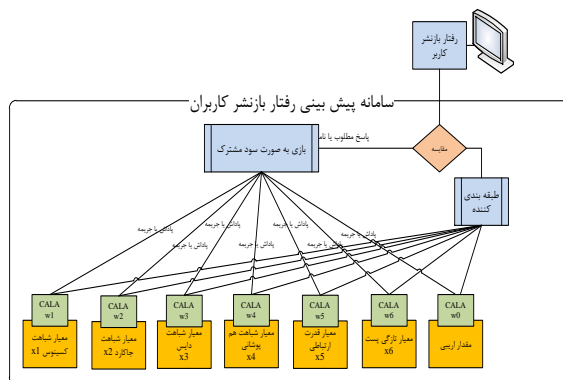
ب) روش استفاده از برنامه‌های کاربردی جمع‌آوری داده: استفاده از ابزارهای خزنده<sup>۱</sup> توئیتر برای جمع‌آوری داده‌های مورد نیاز، به عنوان روش مناسب در بسیاری از پژوهش‌ها،

برای ارزیابی همگرایی از یک حد آستانه  $E_{min}$  استفاده می‌گردد. تعیین حد آستانه به صورت یک مصالحه بین کارایی و دقت صورت می‌گیرد. در مقالات متعدد مقدار حد آستانه آنتروپی را عددی در بازه [۰/۱, ۰/۱] در نظر گرفته می‌شود [۳۹]. برای نمونه بعد از ارزیابی‌های متعدد  $E_{min} = 0.03$  در این مقاله استفاده شده است. شکل (۲) کلیات روش پیشنهادی را نشان می‌دهد.



شکل ۲- نمودار روندنما روش پیشنهادی برای تعیین ضرایب متغیرهای مدل‌سازی

بنابراین، روش پیشنهادی بایستی دارای روش یادگیری بر اساس شش معیار مؤثر و یک مقدار برای ارزیابی باشد. برای تعیین وزن (ضرایب) هر یک از این معیارها و مقدار ارزیابی، برای هر یک از آن‌ها یک FALA به صورت تیمی از اتوماتاهای یادگیر در نظر گرفته شود. محیط به صورت P-model دارای نشانک تقویتی {0,1} می‌باشد که صفر نشان دهنده عدم بازنشر و یک نشان دهنده بازنشر پست است.



شکل ۳- نمودار دید کلی روش پیشنهادی

<sup>۱</sup> Crawler API

## ۵-۲- معیارهای ارزیابی

برای ارزیابی روش پیشنهادی، از معیارهای معتبر در زمینه‌های مشابه استفاده شده است. قبل از معرفی معیارها به ارائه یک سری از تعاریف اولیه مطابق مسئله، می‌پردازیم. مثبت صحیح<sup>۲</sup> (TP): یک پست بازنشر شده، به درستی به عنوان پست بازنشر شده، تشخیص داده می‌شود. مثبت کاذب<sup>۳</sup> (FP): یک پست بازنشر نشده، به اشتباه به عنوان پست بازنشر شده، تشخیص داده می‌شود. منفی صحیح<sup>۴</sup> (TN): پست بازنشر نشده، به درستی به عنوان پست بازنشر نشده، تشخیص داده می‌شود. منفی کاذب<sup>۵</sup> (FN): پست بازنشر شده، به اشتباه به عنوان پست بازنشر نشده، تشخیص داده می‌شود.

میزان حساسیت<sup>۶</sup>: این معیار، بعضاً با عنوان نرخ مثبت صحیح<sup>۷</sup> و یا بازیابی<sup>۸</sup> نیز، شناخته می‌شود. این معیار بر اساس رابطه (۲۸)، محاسبه می‌گردد. همان‌طور که پیش‌تر اشاره شد، اگر یک نمونه پست در داده واقعی بازنشر شده است و روش پیشنهادی، بازنشر این پست را درست پیش‌بینی نماید، این یک نمونه مثبت صحیح به شمار می‌آید. در این رابطه، TP و FN به ترتیب، مثبت صحیح و منفی کاذب، می‌باشند.

$$Sensitivity = \frac{TP}{TP + FN} = TNR = recall \quad (28)$$

تشخیص<sup>۹</sup>: این معیار در بعضی از مراجع به عنوان بازیابی منفی<sup>۱۰</sup>، شناخته می‌شود. اگر یک نمونه پست، در داده واقعی بازنشر نشده است و روش پیشنهادی نیز تصمیم عدم بازنشر را درست پیش‌بینی نماید، این نمونه به صورت مثبت کاذب، در نظر گرفته می‌شود. در رابطه (۲۹)، طریق محاسبه این معیار نشان داده شده است. در این رابطه، TP و FN به ترتیب، مثبت صحیح و منفی کاذب، می‌باشند.

$$Specificity = \frac{TN}{TN + FP} = TNR = recall - \quad (29)$$

نرخ خطا<sup>۱۱</sup>: در صورتی که یک نمونه پست، توسط کاربر در داده واقعی بازنشر نشود، اما روش پیشنهادی به اشتباه بازنشر آن را پیش‌بینی کند، یک نمونه منفی صحیح رخ داده است. نرخ خطا طبق رابطه (۳۰) محاسبه می‌گردد.

به کار گرفته می‌شود [۴۵ و ۴۶]. به طور کلی، مجموعه داده‌های پست‌های عمومی توئیتر، از طریق API توئیتر جریان<sup>۱</sup> (رابط برنامه‌نویسی برنامه) در دسترس است. این ابزار، کاربران را قادر می‌سازد تا با تعیین مشخصات مورد نظر، به داده دسترسی داشته باشند. API توئیتر جریان، سه سطح دسترسی به داده را فراهم می‌آورد: الف) Sprintzer (تا سقف یک درصد از تمام پست‌های عمومی)، ب) "Gardenhose" (تا سقف ده درصد از پست‌های عمومی)، ج) "FireHose" (بدون محدودیت دسترسی به پست‌های عمومی).

دو روش آخر یعنی "Firehose" و "Gardenhose"، دارای اهداف تجاری می‌باشند و سرویس رایگان نیستند؛ "Sprintzer" روش ترجیحی بسیاری از پژوهش‌هاست زیرا به صورت آزادانه برای عموم قابل دسترس است.

با توجه به موارد مطرح شده در یک فرآیند نظام‌مند، بنا به مقتضیات مسئله، مجموعه دادگان مورد نیاز، جمع‌آوری گردید. در این مقاله، سه مجموعه داده، با ویژگی‌ها مختلف جمع‌آوری شده است. جدول (۲) مشخصات مربوط این سه مجموعه داده را نشان می‌دهد.

این سه مجموعه، موضوعات مختلف را در ارتباط با پست‌ها پوشش می‌دهند. مجموعه اول، مربوط به کاربران و پست‌های مرتبط با حوزه فناوری می‌باشد. در مجموعه دوم، داده‌های یک زمینه سیاسی و اجتماعی، جمع‌آوری شده است و در مجموعه سوم، پست‌های سرگرمی و روزمره، در نظر گرفته شده‌اند.

جدول ۳- مشخصات مجموعه دادگان ارزیابی

مجموعه داده	نام	تعداد پست‌ها	تعداد کاربران	تعداد بازنشرها
مجموعه داده (۱)	Steve Jobs Death	۱۹۸۳۴	۱۱۱۵۵	۱۵۸۱۳
مجموعه داده (۲)	US Election	۲۵۳۶۸	۵۷۲۷۶	۷۴۱۰۶
مجموعه داده (۳)	☺ emoticon	۱۳۹۵۶	۱۱۶۲	۲۱۵۷۸

<sup>7</sup> True Positive Rate

<sup>8</sup> Recall

<sup>9</sup> Specificity

<sup>10</sup> Recall-

<sup>11</sup> Miss Rate

<sup>1</sup> Twitter's Streaming API

<sup>2</sup> True Positive

<sup>3</sup> False Positive

<sup>4</sup> True Negative

<sup>5</sup> False Negative

<sup>6</sup> Sensitivity

است، موارد عدم بازنشر را بهتر از روش های دیگر، تشخیص دهد. علت این امر در یادگیری برخط روش پیشنهادی و قدرت بالای این روش در تحمل داده های پرت و نویزدار می باشد.

جدول ۴- مقایسه نرخ حساسیت روش پیشنهادی

معیار حساسیت	روش پیشنهادی	درخت تصمیم	لجستیک رگرسیون
مجموعه داده (۱)	۰/۸۹۷۹	۰/۵۹۷۲	۰/۸۳۹۵
مجموعه داده (۲)	۰/۶۴۸۹	۰/۴۹۰۱	۰/۵۱۲۳
مجموعه داده (۳)	۰/۹۴۵۲	۰/۶۶	۰/۵۶۹۸
میانگین	۰/۸۳۰۷	۰/۵۸۴۶	۰/۶۴۰۵

جدول ۵- مقایسه معیار تشخیص روش پیشنهادی

معیار تشخیص	روش پیشنهادی	درخت تصمیم	لجستیک رگرسیون
مجموعه داده (۱)	۰/۸۹۴۱	۰/۵۳۱۷	۰/۴۳۸۰
مجموعه داده (۲)	۰/۷۳۶۲	۰/۵۳۱۶	۰/۶۰۳۶
مجموعه داده (۳)	۰/۷۰۱۹	۰/۵۳۸	۰/۷۱۱۳
میانگین	۰/۷۷۷۴	۰/۵۳۳	۰/۵۸۴۳

بر اساس معیار نرخ خطا، روشی بهترین عملکرد را دارد که در تشخیص پست های بازنشر نشده، عملکرد بهتری داشته باشد. جدول ۶ به ارائه نتایج ارزیابی نرخ خطا در روش های مختلف پرداخته است. همانند دو معیار قبلی، روش پیشنهادی، بهترین عملکرد را به خود اختصاص داده است. روش لجستیک رگرسیون، بدترین عملکرد را بین همه روش ها به صورت میانگین، داشته است. نکته جالب توجه در نتایج، عملکرد مشابه روش درخت تصمیم، در هر سه مجموعه داده، می باشد.

نتایج ارزیابی معیار دقت روش های مختلف در جدول ۷، آورده شده است. دقت، یکی از پرکاربردترین معیارهای ارزیابی روش های پیش بینی و کلاس بندی است. هر چه نسبت میزان پیش بینی درست تصمیم بازنشر، به پیش بینی های نادرست، بیشتر باشد، دقت روش بالاتر خواهد بود.

جدول ۶- مقایسه نرخ خطا روش پیشنهادی

$$\text{Miss Rate} = \frac{TN}{TN + FP} = FPR \quad (30)$$

$$= 1 - \text{Specificity}$$

دقت! این معیار نشان می دهد که پیش بینی های تصمیم بازنشر، تا چه حد با عملکرد کاربران در داده واقعی منطبق می باشد. به عبارت دیگر چند مورد از پیش بینی تصمیم بازنشر، در عمل نیز بازنشر شده اند. طریقه محاسبه این معیار، در رابطه (۳۱) نشان داده شده است.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (31)$$

F measure: این معیار، میانگین موزون دقت و بازیابی می باشد.  $\beta$  پارامتری است که توازن را بین این دو معیار فراهم می نماید. همان طور که در رابطه (۳۲) مشاهده می شود، در صورتی که  $\beta = 1$  باشد،  $F_1$  برابر با میانگین موزون دقت و بازیابی می باشد. در صورتی که  $\beta > 1$  باشد این معیار، مبتنی بر بازیابی خواهد شد. به همین صورت اگر  $\beta < 1$  باشد، این معیار مبتنی بر دقت خواهد بود. در ارزیابی روش پیشنهادی از میانگین موزون دقت و بازیابی (ضریب مساوی یک)، استفاده می شود.

$$F_1 = (\beta^2 + 1) \frac{\text{precision} \cdot \text{recall}}{\beta^2 \text{precision} + \text{recall}} \quad (32)$$

$$(0 \leq \beta \leq \infty)$$

### ۵-۳- نتایج ارزیابی

در ادامه بخش ارزیابی، نتایج ارزیابی روش پیشنهادی و مقایسه آن با دیگر روش ها ارائه می گردد. نتایج ارزیابی ها نشان دهنده کیفیت روش پیشنهادی در مقایسه با دیگر روش ها می باشد. در این نتایج روش پیشنهادی مبتنی بر تیمی از اتوماتاهای یادگیر با اقدام متناهی ToFALA<sup>۲</sup> می باشد. برای مقایسه روش پیشنهادی از مدل سازی به کمک درخت تصمیم و لجستیک رگرسیون نیز استفاده شده است. جدول ۴، مقادیر دقیق حساسیت روش های مختلف ارزیابی شده را نشان می دهد. در بررسی نتایج، نکته حائز اهمیت، دقت بالای روش پیشنهادی در مقایسه با دیگر روش هاست. روش درخت تصمیم، عملکرد چندان مناسبی در هر سه مجموعه داده، نداشته است. روش لجستیک رگرسیون، در مجموعه داده اول، عملکرد بسیار خوبی داشته است. همان طور که در جدول ۵، مشاهده می شود، در معیار تشخیص نیز، روش پیشنهادی به صورت میانگین، بهترین عملکرد را به خود اختصاص داده است. این روش توانسته

<sup>2</sup> Team of FALA

<sup>1</sup> Precision



به کمک درخت تصمیم و لجستیک رگرسیون، قابلیت‌های اتوماتای یادگیر، بیش از پیش، مشخص می‌گردد.

جدول ۸- مقایسه F measure روش پیشنهادی

معیار F measure	روش پیشنهادی	درخت تصمیم	لجستیک رگرسیون
مجموعه داده (۱)	۲/۶۹۳۸	۱/۷۹۱۶	۲/۵۱۸۵
مجموعه داده (۲)	۱/۹۴۶۸	۱/۴۷۰۵	۱/۵۳۷۱
مجموعه داده (۳)	۲/۸۳۵۶	۲	۱/۷۰۹۶
میانگین	۲/۴۹۲۱	۱/۷۵۴	۱/۹۲۱۷

#### ۴-۵- امکان‌سنجی نظری پیشنهادی

در این مقاله به منظور امکان‌سنجی روش پیشنهادی از دو روش تحلیل نظری و آزمایش تجربی استفاده شده است.

#### الف) تحلیل نظری

تحلیل روش پیشنهادی در این بخش به کمک مفاهیم نظریه بازی‌ها صورت می‌گیرد. در نظریه بازی‌ها هر بازی به صورت یک سه تایی  $\langle I, A, F \rangle$  تعریف می‌گردد. که در این سه تایی،  $I$  نشان‌دهنده تعداد بازیگران، و  $A = \{A_1, A_2, \dots, A_I\}$  اطلاعات و اقدامات ممکن برای هر بازیگر در نقطه تصمیم است. در این سه تایی، تابع  $F = \{F^1(\alpha), F^2(\alpha), \dots, F^I(\alpha)\}$  یک مجموعه تابع سود برای هر خروجی  $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_i\}$  می‌باشد که  $\alpha_i$  اقدام انتخاب شده توسط بازیگر  $i$  است. هر بازیگر فقط سیگنال سود را دریافت می‌نماید و هیچ دانشی در ارتباط با تابع پاداش ندارد.

تعریف ۳-۶: بر پایه مطالب بیان شده در این مسئله، می‌توان گفت پروفایل  $\alpha^* = \{\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*\}$  یک نقطه بهینه برای بازی است اگر برای هر  $1 \leq i \leq N$  و هر پروفایل  $\alpha'$  رابطه (۳۳) برقرار باشد.

$$F^i(\alpha^*) \geq F^i(\alpha') \quad (33)$$

به عبارت دیگر  $\alpha^*$  یک بیشینه محلی برای  $F^i$  و نقطه تعادل نش برای بازی است.

تعریف ۳-۷: بازی سود مشترک یک نمونه خاصی از بازی است که در آن  $F^i(\cdot) = F(\cdot)$  می‌باشد. به بیان بهتر در این بازی همه بازیگران  $i$  فقط یک سود یکسان دریافت می‌نمایند. حالا نقطه‌ای بهینه در نظر گرفته می‌شود اگر رابطه (۳۴) برقرار باشد. و به طوری که  $N(\alpha^*) = \{\alpha \in D : \alpha, \alpha^* \text{ differ in only one component}\}$

معیار نرخ خطا	روش پیشنهادی	درخت تصمیم	لجستیک رگرسیون
مجموعه داده (۱)	۰/۱۰۵۸	۰/۴۶۸۲	۰/۵۶۱۹
مجموعه داده (۲)	۰/۲۶۳۷	۰/۴۶۸۳	۰/۳۹۶۰
مجموعه داده (۳)	۰/۲۹۸۰	۰/۴۶۱۵	۰/۲۸۸۶
میانگین	۰/۲۲۲۵	۰/۴۶۶۰	۰/۴۱۵۶

جدول (۷) مقایسه معیار دقت روش‌های پیشنهادی

معیار دقت	روش پیشنهادی	درخت تصمیم	لجستیک رگرسیون
مجموعه داده (۱)	۰/۸۳۰۱	۰/۴۲۱۵	۰/۵۳۵۴
مجموعه داده (۲)	۰/۷۱۷۶	۰/۵۷۴۷	۰/۵۸۴۹
مجموعه داده (۳)	۰/۶۹	۰/۶۱۸۱	۰/۶۵۴۳
میانگین	۰/۷۴۵۹	۰/۵۳۸۱	۰/۵۹۱۵

همان‌طور که در جدول ۶ مشاهده می‌شود، روش پیشنهادی در این معیار، بهترین عملکرد را داشته است. دقت پایین روش یادگیری به کمک درخت تصمیم، نسبت به دیگر روش‌ها در هر سه مجموعه داده، بسیار جالب است. در پیاده‌سازی‌های صورت گرفته، مشاهده شد که این روش، در مقایسه با دیگر روش‌ها سرعت بالاتری دارد. هر چه تعداد متغیرهای یادگیری این روش بالاتر رود، دقت این روش افت پیدا می‌کند.

در جدول ۸، مقایسه نتایج ارزیابی معیار F-measure روش‌های مختلف را نشان می‌دهد. همان‌طور که پیش‌تر اشاره شد، F-measure به کار گرفته شده در این مقاله، میانگین موزون دقت و بازیابی (حساسیت) می‌باشد ( $\alpha = \beta$ ). همان‌طور که اشاره شد، میزان معیار  $F$ -measure، ارتباط مستقیمی به دقت و بازیابی روش‌ها دارد. هر دو روش پیشنهادی، بهترین عملکرد را داشته‌اند. نکته جالب در این جدول، پایین بودن مقدار این معیار برای روش درخت تصمیم است. لجستیک رگرسیون، در هر دو معیار بازیابی و دقت، عملکرد مناسب تری نسبت به روش درخت تصمیم داشته است. روش پیشنهادی مبتنی بر تیم اتوماتاهای یادگیر، در معیارهای مختلف عملکرد بهتری نسبت به روش‌های دیگر داشته است. با مقایسه دو روش مدل‌سازی

داده‌های مختلف متفاوت است)، توانسته به نرخ همگرایی در حدود نود درصد، دست یابد. به عبارت دیگر، روش پیشنهادی در حدود نود درصد موارد، تخمین درستی انجام داده است. با توجه به حد آستانه آنتروپی، بعد از طی گام‌های مشخص، میزان همگرایی در گام‌های بعدی تغییر چندانی نداشته است.

#### ۶- محدودیت‌های پژوهش و نتیجه‌گیری

برخی از محدودیت‌های این پژوهش مرتبط با پیچیدگی تحلیل روابط در اجتماعات برخط می‌باشد. تحلیل روابط بین پیگیری کنندگان و پیگیری شوندگان به منظور مدل‌سازی رفتار بازنشر کاربران، بسیار دشوار می‌باشد. روابط بین کاربران به صورت پویا در حال تغییر می‌باشد و ممکن است تابع پارامترهایی خارج از محیط اجتماع برخط باشد. تحلیل این روابط تنها با اکتفا کردن به داده‌های ذخیره‌شده در کارگزار<sup>۱</sup> این اجتماعات، ممکن است نتایج دقیقی به همراه نداشته باشد. برای مثال تأثیرات کاربران ممکن است بر اساس ارتباطات غیرمجازی دچار تغییر گردد که این خود به پیچیدگی کار روی داده‌های واقعی می‌افزاید. محدودیت‌های ناشی از مجموعه دادگان نوعی دیگری از محدودیت‌هایی است که در این تحقیق با آن مواجه هستیم. استفاده از ابزارهای لازم نظیر API های اجتماعات برخط مانند توئیتر و جمع‌آوری داده‌های مورد نیاز در بازه زمانی مشخص، پیچیدگی‌های خاص خود را دارند. یافتن داده‌های باکیفیت، پیش‌پردازش داده‌ها در حجم مناسب مسئله، چندان ساده به نظر نمی‌رسد. این ابزارها از جهت حجم اطلاعات محدودیت‌هایی نظیر، دریافت میزان مشخصی از اطلاعات در ساعت، اعمال می‌نمایند که کار بر روی مجموعه داده دلخواه با کاربران مشخص را، عملاً غیرممکن می‌سازند. در مورد استفاده از مجموعه دادگان آماده، بایستی این نکته را در نظر گرفت که، این مجموعه داده‌ها اغلب با توجه به ملاحظات حریم شخصی دارای حداقل اطلاعات ممکن هستند. این‌گونه دادگان اغلب پیش‌پردازش شده‌اند و بنا به سیاست‌های اتخاذ شده مورد بازبینی قرار گرفته‌اند. بعضاً این بازبینی‌ها، در کیفیت نتایج ممکن است تأثیرگذار باشد. از دیگر محدودیت‌های این تحقیق، اکتفا به استفاده از توئیتهای زبان انگلیسی است که کاربردهای نسبتاً کمی، در مطالعه اجتماعات برخط فارسی‌زبان دارد.

هر عنصر از  $D \equiv \prod_{i=1}^l A_i$  مجموعه ای از سطر از اقدامات انتخابی توسط همه بازیگر  $I$  می‌باشد.

$$F^i(\alpha^*) \geq F^i(\alpha') \quad \forall (\alpha') \in N(\alpha^*) \quad (34)$$

لم ۳-۱: تیمی از FALA های استفاده شده در این مقاله، به صورت یک بازی با سود مشترک می‌باشد.

اثبات: به وضوح می‌توان نشان داد که تیمی از FALA های استفاده شده در این مقاله، به صورت یک بازی با سود مشترک است. به صورتی که هر FALA به صورت یک بازیگر بوده و فضای انتخاب هر بازیگر به صورت مجموعه اقدامات ممکن برای هر FALA می‌باشد. مانند همه بازی‌های با سود مشترک، بعد از انتخاب اقدامات توسط FALA ها، یک سود مشترک و مساوی دریافت می‌شود که به صورت سیگنال تقویتی است.

قضیه ۳-۱: زمانی که یک بازی با سود مشترک برای تیمی از FALA ها تعریف می‌شود و همه اتوماتاهای یادگیر از قانون رابطه (۴) و (۵) برای به‌روزرسانی استفاده می‌کنند (مطابق [۴۷])، اگر گام‌های یادگیری به صورت مناسبی کوچک در نظر گرفته شود، این تیم از FALA به طور قطع به یک نقطه بیشینه محلی همگرا خواهند شد. این نقطه همان نقطه تعادل نش بازی می‌باشد. در مراجع متعدد نظیر [۳۶ و ۴۷] اثبات این قضیه آورده شده است که در این مقاله از اثبات آن صرف نظر شده است.

#### ب) آزمایش تجربی


برای ارزیابی روش پیشنهادی، ابتدا امکان‌سنجی همگرایی روش پیشنهادی، مورد بررسی قرار می‌گیرد.

همان‌طور که در نمودارهای (۴) مشاهده می‌شود، روش پیشنهادی برای هر سه مجموعه داده به سرعت همگرا می‌گردد. برای تفسیر این نمودارها، اندازه‌گیری نرخ همگرایی در هر سه نمودار، بعد از پنجاه گام اولیه صورت گرفته است. این پنجاه گام برای یادگیری اولیه روش پیشنهادی لازم است. نرخ همگرایی هر سه نمودار بعد از پنجاه گام در حدود پنجاه درصد می‌باشد. به عبارت دیگر، در نیمی از موارد این روش همگرا شده و توانسته تخمین درستی داشته باشد. هرچه از گام پنجاهم می‌گذرد، نرخ همگرایی روش پیشنهادی افزایش پیدا می‌کند. روش پیشنهادی بعد از طی حدود پانصد گام ( در مجموعه

<sup>1</sup> Server

مقاله، روشی جدید برای مدل‌سازی رفتار بازنشر کاربران ارائه گردید.

علت این امر نبود مجموعه دادگان مستند فارسی از رفتار کاربران فارسی‌زبان در اجتماعات برخط می‌باشد. در این



شکل ۴- نرخ همگرایی روش پیشنهادی برای سه مجموعه داده ارزیابی

صورت که به هر از متغیرهای مدل، یک اتوماتای یادگیر تصادفی به عنوان بازیگران این بازی اختصاص پیدا کرده بود. با هر انتخاب اقدام توسط هر یک از اتوماتاها، بسته به پاسخ مطلوب یا نامطلوب محیط، کلیه اتوماتاهای یادگیر پاداش یا جریمه می‌شوند. این روند تا رسیدن به همگرایی مبتنی بر حد آستانه آنتروپی ادامه پیدا می‌کند. روش پیشنهادی با استفاده از سه مجموعه داده نسبتاً بزرگ ارزیابی و نتایج این ارزیابی‌ها نشان‌دهنده کیفیت بالای مدل‌سازی پیشنهاد شده دارد.

رفتار بازنشر کاربران از این جهت اهمیت دارد که می‌تواند مدلی از انتقال اطلاعات بین کاربران در اجتماعات برخط را ارائه دهد. این مدل‌سازی کاربردهای متنوعی در آموزش، بازاریابی، تبلیغات و غیره دارد. در روش پیشنهادی ابتدا به شناسایی دقیق متغیرهای مدل و روش اندازه‌گیری هر یک از آن‌ها پرداخته شد. سپس با توجه به ماهیت مسئله و تصادفی بودن رفتار بازنشر کاربران در یک محیط دارای عدم قطعیت، از روش یادگیری تقویتی مبتنی بر اتوماتای یادگیر تصادفی استفاده شد. این روش یادگیری مدل، به صورت یک بازی با سود مشترک طراحی شده بود. به این

## مراجع

- [1] سید مهدی قریشی و نگین دانشپور، "بهبود عبارت نگهداری دید در پایگاه داده تحلیلی"، نشریه مدل‌سازی در مهندسی. دوره ۱۶، شماره ۵۵، زمستان ۱۳۹۷، صفحه ۱۰۱-۱۱۱.

- [2] سلیمه ضیالددینی و مینا ابارقی، "ارائه یک روش جدید برای تخمین مقادیر گمشده در مجموعه داده"، نشریه مدل سازی در مهندسی، مقاله ۱۳، دوره ۱۶، شماره ۵۵، زمستان ۱۳۹۷، صفحه ۱۵۵-۱۶۲.
- [3] سامان کشوری، حسن نادری و مجید غیوری ثالث، "آبگیر داده: رویکردی نوین جهت مدیریت و تحلیل بی درنگ داده های حجیم"، نشریه مدل سازی در مهندسی، مقاله ۱۲، دوره ۱۶، شماره ۵۵، زمستان ۱۳۹۷، صفحه ۱۳۳-۱۵۴.
- [4] D. Boyd, S. Golder, and G. Lotan, "Tweet, tweet, retweet: Conversational aspects of retweeting on twitter", in Proceedings of the Annual Hawaii International Conference on System Sciences, 2010.
- [5] B. Suh, L. Hong, P. Pirolli, and E. H. Chi, "Want to be retweeted? Large scale analytics on factors impacting retweet in twitter network", 2010 IEEE Second International Conference on Social Computing, Minneapolis, MN, 2010, pp. 177-184.
- [6] S. Petrovic, M. Osborne, and V. Lavrenko, "Rt to win! Predicting message propagation in twitter", Proceedings of the Fifth International Conference on Weblogs and Social Media, Barcelona, Catalonia, Spain, July 17-21, 2011.
- [7] Y. L. Hwong, C. Oliver, M. Van Kranendonk, C. Sammut, and Y. Seroussi, "What makes you tick? The psychology of social media engagement in space science communication", Computers in Human Behavior, Vol. 68, 2017, pp. 480-492.
- [8] K. Crammer, O. Dekel, and J. Keshet, et al., "Online Passive-Aggressive Algorithms", Journal of Machine Learning Research, Vol. 7, 2006, pp. 551-585.
- [9] J. Lu, P. Zhao, and S. C. H. Hoi, "Online Passive-Aggressive Active learning", Machine Learning, Vol. 103, pp. 141-183, 2016.
- [10] B. Suh, L. Hong, P. Pirolli, and E. H. Chi, "Want to be retweeted? Large scale analytics on factors impacting retweet in twitter network", in Proceedings - SocialCom 2010: 2nd IEEE International Conference on Social Computing, PASSAT 2010: 2nd IEEE International Conference on Privacy, Security, Risk and Trust, 2010, pp. 177-184.
- [11] T. R. Zaman, R. Herbrich, J. van Gael and D. Stern, "Predicting Information Spreading in Twitter", Work. Computational Social Science and the Wisdom of Crowds Workshop (colocated with NIPS 2010), 2010.
- [12] Y. Artzi, P. Pantel, and M. Gamon, "Predicting Responses to Microblog Posts", in NAACL, 2012.
- [13] Q. Wu, Ch.J.C. Burges, K.M. Svore, J. Gao, "Ranking, Boosting, and Model Adaptation", Inf. Retr. Boston., 2008.
- [14] P. Luukka, "Feature selection using fuzzy entropy measures with similarity classifier", Expert Systems with Applications, Vol. 38, No. 4, 2011, pp. 4600-4607.
- [15] Q. Zhang, Y. Gong, Y. Guo, and X. Huang, "Retweet Behavior Prediction Using Hierarchical Dirichlet Process", in Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence, 2015.
- [16] T. Zaman, E. B. Fox, and E. T. Bradlow, "A bayesian approach for predicting the popularity of tweets", The Annals of Applied Statistics, Vol. 8, No. 3, 2014, pp. 1583-1611.
- [17] B. Bi and J. Cho, "Modeling a Retweet Network via an Adaptive Bayesian Approach", in Proceedings of the 25th International Conference on World Wide Web - WWW '16, 2016.
- [18] Y. Zhang, Z. Xu and Q. Yang, "Predicting popularity of messages in twitter using a feature-weighted model", International Journal of Advanced Intelligence, 2015.
- [19] L. Hong, O. Dan, and B. D. Davison, "Predicting popular messages in Twitter", in Proceedings of the 20th international conference on World wide web (WWW), 2011, pp. 57-58.
- [20] D. Ienco, F. Bonchi, and C. Castillo, "The meme ranking problem: Maximizing microblogging virality", 2010 IEEE International Conference on Data Mining Workshops, Sydney, NSW, 2010, pp. 328-335.
- [21] R. Yan, M. Lapata, and X. Li, "Tweet Recommendation with Graph Co-Ranking", Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics, (Volume 1: Long Papers), July 2012, pp. 516-525.
- [22] D. Metzler, S. Dumais, and C. Meek, "Similarity Measures for Short Segments of Text", European Conference on Information Retrieval (ECIR 2007), Vol. 4425, 2007, pp. 16-27.

- [23] P. Bhattacharyya, A. Garg, and S. F. Wu, "Analysis of user keyword similarity in online social networks", *Social Network Analysis and Mining*, pp. 1–16, 2010.
- [24] P. Achananuparp, E.-P. Lim, J. Jiang, and T.-A. Hoang, "Who is Retweeting the Tweeters? Modeling, Originating, and Promoting Behaviors in the Twitter Network", *ACM Transactions on Management Information Systems*, Vol. 3, No. 3, 2012, pp. 13:1–13:30.
- [25] Z. Xu and Q. Yang, "Analyzing user retweet behavior on twitter", in *Proceedings of the 2012 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, ASONAM 2012*, 2012, pp. 46–50.
- [26] F. Bonchi, C. Castillo, and D. Ienco, "Meme ranking to maximize posts virality in microblogging platforms", *Journal of Intelligent Information Systems*, Vol. 40, 2013, pp. 211–239.
- [27] A. M. Joshi and M. Trusov, "Are You a 'Viral Star'? Conceptualizing and Modeling Inter-media Virality", *Journal of the Association for Consumer Research*, Vol. 2, No. 2, 2017.
- [28] A. J. Mills, "Virality in social media: The SPIN Framework", *Journal of Public Affairs*, Vol. 12, No. 2, 2012, pp. 162–169.
- [29] G. Gaughan and A. F. Smeato, "Finding new news: Novelty detection in broadcast news", in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Vol. 3689 LNCS, 2005, pp. 583–588.
- [30] L. K. Hansen, A. Arvidsson, F. A. Nielsen, E. Colleoni, and M. Etter, "Good friends, bad news - Affect and virality in twitter", in *Communications in Computer and Information Science*, Vol. 185, 2011, pp. 34–43.
- [31] Y. Chang et al., "Improving recency ranking using twitter data", *ACM Transactions on Intelligent Systems and Technology*, Vol. 4, No. 1, 2013.
- [32] M. Amadei, "An approach to social news recommendation based on focused crawling and sentiment analysis", in *UMAP 2017 - Adjunct Publication of the 25th Conference on User Modeling, Adaptation and Personalization*, 2017.
- [33] K. Wang, M. Bansal, and J. M. Frahm, "Retweet wars: Tweet popularity prediction via dynamic multimodal regression", *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Lake Tahoe, NV, 2018, pp. 1842–1851.
- [34] M. Nagarajan, H. Purohit, and A. Sheth, "A Qualitative Examination of Topical Tweet and Retweet Practices", in *Conference: Proceedings of the Fourth International Conference on Weblogs and Social Media (ICWSM)*, 2010, pp. 295–298.
- [35] T. Hoang and E. Lim, "Virality and Susceptibility in Information Diffusions", *Proceedings of the Sixth International Conference on Weblogs and Social Media. Research Collection School of Information Systems*, 2012, pp. 146–153.
- [36] P. S. Sastry, G. D. Nagendra, and N. Manwani, "A team of continuous-action learning automata for noise-tolerant learning of half-spaces", in *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, Vol. 40, No. 1, Feb. 2010, pp. 19–28.
- [37] M. A. L. Thathachar and P. S. Sastry, "Varieties of learning automata: An overview", in *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, Vol. 32, No. 6, Dec. 2002, pp. 711–722.
- [38] P. S. Sastry, V. V. Phansalkar, and M. A. L. Thathachar, "Decentralized Learning of Nash Equilibria in Multi-Person Stochastic Games With Incomplete Information", in *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 24, No. 5, May 1994, pp. 769–777.
- [39] M. A. L. Thathachar and P. S. Sastry, *Introduction in Networks of Learning Automata*, Boston, MA: Springer US, 2004, pp. 1–49.
- [40] L. Hong, R. Bekkerman, J. Adler, and B. D. Davison, "Learning to rank social update streams", *Proc. 35th Int. ACM SIGIR Conf. Res. Dev. Inf. Retr. - SIGIR '12*, p. 651, 2012.
- [41] N. A. Alawad, A. Anagnostopoulos, S. Leonardi, I. Mele, and F. Silvestri, "Network-Aware Recommendations of Novel Tweets", in *Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval - SIGIR '16*, 2016.
- [42] W. Wang, L. Duan, A. Koul, and A. Sheth, "YouRank: Let User Engagement Rank Microblog Search Results", in *8th International AAAI Conference on Weblogs and Social Media*, 2014.

- [43] E. Diaz-Aviles, A. Stewart, E. Velasco, K. Denecke, and W. Nejdl, "Towards personalized learning to rank for epidemic intelligence based on social media streams," in Proceedings of the 21st international conference companion on World Wide Web - WWW '12 Companion, 2012, p. 495.
- [44] I. Uysal and W. B. Croft, "User oriented tweet ranking: A filtering approach to microblogs", in International Conference on Information and Knowledge Management, Proceedings, 2011, pp. 2261–2264.
- [45] G. Valkanas, A. Saravanou, and D. Gunopulos, "A faceted crawler for the Twitter service", Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). 2014.
- [46] M. Bošnjak, E. Oliveira, J. Martins, E. M. Rodrigues, and L. Sarmiento, "TwitterEcho - A Distributed Focused Crawler to Support Open Research with Twitter Data", WWW - MSND Work., 2012.
- [47] M. A. L. Thathachar and P. S. Sastry, Networks of Learning Automata : Techniques for Online Stochastic Optimization. Springer US, 2004.