

# نشریه علمی پدافند غیرعامل

سال سیزدهم، شماره ۳، پاییز ۱۴۰۱، (پیاپی ۵۱): صص ۴۵-۵۶

علمی - ترویجی

## پیش‌بینی ناآرامی‌های مردمی با استفاده از شبکه‌های اجتماعی، مبتنی بر

### یادگیری ماشین در پردازش زبان طبیعی

رسول عباسی<sup>۱</sup>، محمدعلی جوادزاده<sup>۲\*</sup>

تاریخ دریافت: ۱۴۰۰/۰۵/۲۴

تاریخ پذیرش: ۱۴۰۱/۰۵/۰۹

#### چکیده

امروزه علاقه به پیش‌بینی و تشخیص رویدادها با استفاده از داده‌های موجود در شبکه‌های اجتماعی، افزایش یافته است. شبکه‌های اجتماعی را می‌توان به‌عنوان حسگرهای جامعه نام برد، چرا که کاربران آن همواره نظرات مثبت و منفی خود را نسبت به اتفاقات دنیای پیرامون خود بیان می‌کنند که نتیجه این تعاملات، محیطی است مملو از واکنش‌های بلادرنگ به حوادث دنیای واقعی. شبکه‌های اجتماعی یکی از بهترین ابزارها برای ارزیابی جامعه و پیش‌بینی حوادث آن است. اگر چه تشخیص و دسته‌بندی خودکار حوادث و رویدادها، به ویژه ناهنجاری‌های اجتماعی مانند اغتشاش یک کار پیش‌پاافتاده است اما برای دولت‌ها و سازمان‌های امنیتی که نیاز به پاسخگویی سریع و متناسب دارند، از ارزش بالایی برخوردار است؛ زیرا می‌توان هزینه‌ها و خسارات ناشی از این ناآرامی‌ها را کاهش داد. برای این چالش، ما یک چارچوب پیش‌بینی رویداد طراحی کردیم که به کمک آن می‌توان "رویدادهای اخلاص‌گر" که امنیت و نظم اجتماعی را تهدید می‌کنند از رویدادهای روزمره شناسایی کرد. برای انجام این کار از روش‌های پردازش زبان طبیعی به‌منظور درک متون، حذف محدودیت‌های زبان انسان، تحلیل احساس و موضوع استفاده کردیم، و در نهایت با استفاده از روش‌های یادگیری ماشین مانند Naïve Bayes و Support Vector Machines به طبقه‌بندی حوادث و رویدادها پرداختیم. در پایان چارچوب خود را در یک مجموعه داده بزرگ و واقعی از توییت‌های ارزیابی کردیم تا کارایی و اثربخشی سامانه خود را برای پیش‌بینی رویدادهای آینده نشان دهیم. نتایج به‌دست آمده نشان داد که چارچوب پیشنهادی با دقت ۷۹ درصد توانایی تشخیص توییت‌های ناراضی‌تری را دارد. همچنین موفق به استخراج اطلاعات مفید از این توییت‌ها در غالب ۵ موضوع شدیم که با دقت ۴۰ درصد اطلاعاتی شامل مکان، زمان، اشخاص، اهداف و عوامل مرتبط با یک رویداد را استخراج کرد.

**کلید واژه‌ها:** پیش‌بینی رویداد، تحلیل احساس، تحلیل موضوع، شبکه‌های اجتماعی، پیش‌بینی حوادث و ناهنجاری‌های اجتماعی

<sup>۱</sup> دانشجوی کارشناسی ارشد دانشگاه جامع امام حسین (ع)، تهران، ایران

<sup>۲</sup> استادیار دانشگاه جامع امام حسین (ع)، تهران، ایران (Javadzade@ihu.ac.ir) - نویسنده مسئول

## ۱- مقدمه

رسانه‌ها با میلیاردها کاربر در سراسر جهان، نقش مهمی در سازماندهی رویدادهای مختلف اجتماعی از جمله اغتشاشات و انواع مشابه اقدامات جمعی دارند. متأسفانه در طول دهه گذشته، شاهد استفاده از شبکه‌های اجتماعی به ویژه توئیتر، اینستاگرام، تلگرام و واتساپ برای سازماندهی اطلاعات و بسیج مردم برای ایجاد ناامنی و اعتراضات بوده‌ایم.

تحقیقات در سال‌های اخیر نقش مهم استفاده از داده‌های شبکه‌های اجتماعی در شرایط فاجعه را کشف کرده و نشان داده است که اطلاعات پخش شده از طریق رسانه‌های اجتماعی می‌تواند در تشخیص و پیش‌بینی شرایط بحرانی نقش مهمی را ایفاء کند [۳]. به‌عنوان مثال در سال‌های اخیر تحقیقات فراوانی بر روی حوادثی همچون بهار عربی، ناآرامی‌های لندن، اعتراضات تایلند، جلیقه زردهای فرانسه، اغتشاش‌های سال ۸۸ ایران و همچنین درگیری‌های مربوط به گرانی بنزین انجام شده که در ادامه نیز به برخی از آن‌ها پرداخته شده است. این تحقیقات نشان می‌دهد که به کمک روش‌های پردازش زبان طبیعی و یادگیری ماشین (مانند پردازش احساس و تحلیل موضوع) می‌توان سامانه‌هایی را پیاده‌سازی کرد تا درک بالایی از ناهنجاری‌های اجتماعی را قبل از وقوع آن و یا هنگام رسیدن به شرایط بحرانی داشت.

تشخیص دلایل مختلف ناآرامی‌ها، آگاهی از زمان و مکان گردهمایی‌ها، عوامل تشدید اعتراضات و ایجاد اغتشاش، تشخیص عوامل نفوذی و پشت پرده اغتشاش‌ها، تجزیه و تحلیل بازدهی و آثار اقدامات دولت‌ها برای جلوگیری از اغتشاشات و بی‌نهایت دلایل دیگر همگی بخشی از کاربردهای شبکه‌های اجتماعی در هنگام وقوع شرایط بحرانی مانند اغتشاشات است. اما برای رسیدن به یک سامانه و چارچوب کلی چالش‌های فراوانی نیز وجود دارد.

یک چالش این است که متن‌های موجود در شبکه‌های اجتماعی اغلب دارای محدودیت‌هایی هستند، مثلاً در برخی از مواقع فقط مقدار کمی از متن برای تجزیه و تحلیل و دستیابی به بینش و نتیجه کلی در دسترس است. در متن، چالش‌های دیگری نیز وجود دارد، مانند استفاده مکرر از کلمات غیر رسمی، نامنظم و مختصر، تعداد زیاد غلط‌های املائی و دستوری، استفاده از شکله‌ها و ایموجی‌ها به جای متن و استفاده از ساختار جمله‌های نامناسب و زبان‌های مختلط. همچنین برخی از زبان‌ها بیش از دیگران ابهام‌برانگیز هستند، به‌عنوان مثال، کاربران فارسی به شدت از گویش‌های مختلف ترکی، کردی، لری و دیگر لهجه‌ها استفاده می‌کنند. علاوه بر آن گاهی از ترکیب حروف لاتین و فارسی در جملات خود استفاده می‌کنند. این گویش‌ها ممکن

شهروندان یک جامعه همواره به‌منظور مطالبه حقوق شهروندی خود و یا تأکید بر ابراز وجود در اعتراض‌ها، تظاهرات و چه بسا اغتشاشات شرکت می‌کنند. مردم یک کشور به امید آینده‌ای بهتری برای خانواده، فرزندان و جامعه خود به اعتراض رو می‌آورند تا کمبودها، درخواست‌ها و تأیید یا عدم تأیید یک وضعیت خاص را ابراز کنند. حتی اگر اکثریت اعتراضات مسالمت‌آمیز باشد، طبیعی است که برخی از آن‌ها منجر به خشونت و تخریب شود و در نتیجه خسارات مالی و یا اثرات روانی بر جامعه وارد کند چرا که در این گردهمایی‌ها همواره تعداد زیادی از شرکت‌کنندگان حضور دارند؛ بنابراین، پیش‌بینی چنین تظاهراتی از قبل برای کاهش هزینه‌های احتمالی امری مهم و حیاتی است.

پیش‌بینی دقیق و به موقع اعتراضات برای مقامات سازمان‌های دولتی این امکان را فراهم می‌کند تا اقداماتی را برای مقابله با خسارات انجام دهند و یا با عوامل پشت پرده رویدادهای مخرب مقابله کنند. از طریق این نوع تجزیه و تحلیل‌ها، سیاستمداران و دانشمندان می‌توانند عوامل تحریک‌کننده احساسات مردم و اطلاعات اصلی در مورد اینکه کجا، چه زمانی و چرا توده‌های مردم دست به اغتشاش می‌زنند را درک کنند.

حساسیت و اهمیت تشخیص درست پیش‌بینی‌ها، زمانی مشخص می‌شود که عدم پیش‌بینی یک اعتراض بزرگ منجر به آن خواهد شد که مقامات دولتی دیرتر به وقایع پیش آمده واکنش نشان دهند و احتمالاً باعث ایجاد هزینه‌ها و خساراتی می‌شود که در غیر این صورت می‌توانست از آن‌ها جلوگیری شود (منفی کاذب) و همچنین پیش‌بینی نادرست از وقوع یک اعتراض باعث بیهوده شمرده شدن هشدارهای عمومی و توصیه‌های خبرگزاری‌ها خواهد شد، از این رو باعث ایجاد احساس ناامنی ناعادلانه می‌شود (مثبت کاذب) [۱].

تجربیات به‌دست آمده از اعتراضات سال‌های گذشته نشان می‌دهد که هر چه تعداد شرکت‌کنندگان یک اعتراض بیشتر باشد، احتمال موفقیت بیشتر شده و دستگیری افراد شرکت‌کننده در آن اعتراض نیز کمتر خواهد شد، در نتیجه معترضین سعی می‌کنند برای تشویق و مشارکت بیشتر به‌منظور بزرگ‌تر کردن جمعیت، از قبل برنامه‌ریزی کرده و اعتراضات را به‌صورت سراسری اعلام کنند.

استفاده از شبکه‌های اجتماعی برای برقراری ارتباط و اشتراک‌گذاری اطلاعات رشد چشمگیری در سال‌های اخیر داشته است [۲]. به لطف رشد روزافزون شبکه‌های اجتماعی، این

آزمایش‌های گسترده‌ای برای ارزیابی اثربخشی چارچوب پیشنهادی با استفاده از مجموعه داده‌های بزرگ در دنیای واقعی (شورش‌های لندن و توییت‌های منتشر شده در منطقه خاورمیانه) انجام داد. مهم‌ترین مشکل چارچوب پیشنهادی آن‌ها وابستگی شدید مدل پیشنهادی به رویدادهای گذشته است. بررسی‌های ما نشان داد که از روی ناآرامی‌های گذشته تنها بخشی از حوادث آینده را می‌توان پیش‌بینی کرد. در واقع یک سامانه پیش‌بینی باید متشکل از یادگیری بدون نظارت نیز باشد تا در حوادث آینده بتواند ویژگی‌های جدید را استخراج کرده تا از دقت بالاتری برخوردار شود.

توییت‌های فاش می‌کند: استفاده از تحلیل توییتی برای پیش‌بینی اعتراضات عمومی [۱]، یک مدل پیشگو مبتنی بر طبقه‌بندی برای پیش‌بینی اعتراضات گسترده بر اساس داده‌های توییت و رفتار توییت کاربران ارائه داد. علاوه بر این، برای بهبود عملکرد پیش‌بینی، ویژگی‌های خاص رویداد (به‌عنوان مثال آمار لایک کردن) را در مدل خود در نظر گرفت. هر دو مدل (با و بدون ویژگی‌های خاص رویداد) اعتراضات پس از انتخابات را با دقت بالا پیش‌بینی می‌کرد. او مدل‌های خود را با یک مورد اعتراض (ممنوعیت مسلمانان به دلیل دستورالعمل ریاست جمهوری در آمریکا) آزمایش کرد و نتایج را در مقاله خود ارائه داد. مهم‌ترین مشکل مدل پیشنهاد شده در مرحله اول یعنی شناسایی سیگنال‌های اولیه است، چرا که سامانه آن‌ها تنها از تعدادی کلمات و هشتک‌های خاص که در اکثر شورش‌ها رایج است استفاده می‌کند. با توجه به اینکه در ابتدای هر ناآرامی هشتک‌های جدیدی برای بسیج همگانی توسط اغتشاشگران انتخاب می‌شود، سامانه پیشنهادی آن‌ها نمی‌تواند در ساعت‌های اولیه ناآرامی‌ها پیش‌بینی‌ها را انجام دهد.

رویکردهای یادگیری ماشین خودکار برای واکنش و هماهنگی در موارد اضطراری از طریق رسانه‌های اجتماعی در پیامدهای یک فاجعه [۴]، به مرور و بررسی مطالعات اخیر در مورد هماهنگی و واکنش اضطراری پرداخته است که شامل مروری کوتاه بر تحقیقات موجود در این زمینه و ارزیابی یافته‌های آنان بود. این مقاله علاوه بر توصیف مدل‌های مختلف یکی از محدودیت‌های تحقیقات فعلی را استفاده از مجموعه داده توییت می‌دانست و معتقد بود که پویایی هماهنگی و پاسخگویی زمانی می‌تواند متفاوت باشد که کاربران از طریق سامانه‌های دیگری غیر از توییت تبادل اطلاعات کنند.

مقاله چارچوبی برای تحلیل رویدادهای اقدام جمعی در توییت [۵]، مدلی برای تجزیه و تحلیل داده‌های توییت ارائه داد که مربوط به رویدادهای اقدام جمعی بود. سپس کاربرد آن را با

است از نظر واژگان، ریخت‌شناسی و هجی با زبان فارسی استاندارد متفاوت باشند و اکثر آن‌ها هجی استاندارد ندارند. علاوه بر این، محبوبیت سرویس‌های شبکه‌های اجتماعی باعث ایجاد اسپم‌ها و سایر عوامل آلوده کننده محتوا مانند تبلیغات، پورنوگرافی، ویروس‌ها، فیشینگ و سایر مطالب مخرب شده است که تجزیه و تحلیل اطلاعات را سخت‌تر می‌کند.

علی‌رغم این چالش‌ها، پیش‌بینی حوادث برای بهبود عملکرد تصمیم‌گیرندگان امری ضروری است بنابراین همچنان یک موضوع تحقیقاتی محبوب برای جامعه علمی است. در این مقاله، ما یک رویکرد جدید برای تشخیص و پیش‌بینی رویدادهای مخرب پیشنهاد کردیم که هدف آن غلبه بر بسیاری از چالش‌های بالا برای ارائه سامانه‌ای جامع به‌منظور کشف حوادث و ناهنجاری‌های اجتماعی مانند اغتشاشات است. این روش مبتنی بر ترکیبی از الگوریتم‌های پردازش زبان طبیعی، الگوریتم‌های یادگیری ماشین نظارت شده و همچنین بدون نظارت برای پیش‌بینی ناآرامی‌ها و تجزیه و تحلیل آن‌ها از منظرهای مختلف است.

در ادامه این مقاله به بررسی کارهای مشابه در این زمینه پرداخته می‌شود و سپس متدولوژی و روش کار سامانه خود را شرح می‌دهیم.

## ۲- کارهای مرتبط

موضوع کلی تشخیص و پیش‌بینی اتفاقات دنیای واقعی به کمک رسانه‌های اجتماعی مورد توجه محققین زیادی قرار گرفته است. تلاش‌های تحقیقات گذشته بر روی شناسایی و ردیابی وقایع در زمان واقعی، تجزیه و تحلیل شبکه‌های اجتماعی و استخراج اطلاعات مفید متمرکز شده است که در ادامه به برخی از کارهای مرتبط پرداخته شده است.

آیا می‌توانیم یک شورش را پیش‌بینی کنیم؟ تشخیص رویداد مخرب با استفاده از توییت [۳]، یک چارچوب یکپارچه برای شناسایی وقایع بزرگ و کوچک در دنیای واقعی با استفاده از شبکه اجتماعی توییت ارائه داد. همچنین در این مقاله چندین آزمایش در مورد ویژگی‌های مختلف ارائه شده است و نشان می‌دهد که چگونه می‌توان آن‌ها را برای تمایز قائل شدن بین وقایع، به ویژه حوادث مخرب اجرا کرد. نتایج تحقیقات آن‌ها نشان داد نمی‌توان جنبه‌های زمانی، مکانی یا محتوایی را به‌طور جداگانه در نظر گرفت. در عوض، ترکیبی از ویژگی‌های پوشش دهنده همه این جنبه‌ها منجر به یک سامانه قوی می‌شود که بهترین نتایج تشخیص رویداد را گزارش می‌کند. او در مقاله خود

بردارهای کلمه از پیش آموزش دیده عملکرد خوبی در کار تحلیل احساسات توپیتر دارد.

مقایسه تحقیق در مورد روش‌های پیش‌پردازش متن در تحلیل احساسات توپیتر [۹]، اثرات روش پیش‌پردازش متن را بر عملکرد طبقه‌بندی احساسات در دو نوع کار طبقه‌بندی مورد بحث قرار داد و عملکردهای طبقه‌بندی شش روش پیش‌پردازش را با استفاده از دو مدل ویژگی و چهار طبقه‌بندی در پنج مجموعه داده توپیتر خلاصه کرد. آزمایش‌ها نشان می‌دهند که طبقه‌بندی کننده‌های Naive Bayes و Random Forest نسبت به رگرسیون لجستیک حساس‌تر هستند.

ما در چارچوب خود تلاش کردیم مشکلات مطرح شده بالا را برطرف کنیم که در ادامه به تفسیر آن پرداخته شده است.

### ۳- تعریف مسئله

یک رویداد در شبکه‌های اجتماعی زمانی معنا پیدا می‌کند که اتفاقی در دنیای واقعی حجم زیادی از متون شبکه اجتماعی را در یک بازه زمانی خاص دربر بگیرد. این رویدادها می‌تواند با یک یا چند ویژگی شامل موضوع، زمان، افراد و مکان مشخص شوند.

یک رویداد مخرب، رویدادی است که در دستیابی به هدف یک رویداد عادی تداخل ایجاد می‌کند یا روال معمول رویداد را قطع می‌کند. رویداد مخرب ممکن است در طی یک یا چند روز ایجاد شود و باعث ایجاد بی‌نظمی و بی‌ثباتی شود [۳].

متون حاوی یک رویداد مخرب معمولاً دارای ویژگی‌های مشترکی هستند که شناسایی و تشخیص آن‌ها را آسان‌تر می‌کند. این متون معمولاً دارای احساس و بار منفی توأم با کلماتی پرخاصگرانه هستند که نارضایتی‌های مردم را منتقل می‌کنند.

هدف ما این است که چارچوبی را ارائه دهیم که بتواند از میان داده‌های استخراج شده از رسانه‌های اجتماعی ناآرامی‌های اجتماعی مانند اغتشاش، آشوب، درگیری و دیگر ناهنجاری‌های جامعه را پیش‌بینی کند. لازم‌ه رسیدن به این چارچوب داشتن یک سامانه تشخیص نارضایتی در متن است که بتواند از میان داده‌های دریافت شده نوعی از ناهنجاری اجتماعی را تشخیص دهد. در ادامه به بررسی روش خود و ذکر مراحل مختلف این روش می‌پردازیم.

### ۴- متدولوژی تحقیق

به‌منظور پیش‌بینی ناآرامی با استفاده از داده‌های موجود در شبکه‌های اجتماعی، سامانه آنالیز و بلادرنگی را پیشنهاد می‌کنیم که شامل پنج مرحله باشد. شکل (۱) نمودار مراحل مختلف این سامانه را نشان می‌دهد.

داده‌های مربوط به اعتراضات در تایلند مورد آزمایش قرار داد. مدل پیشنهادی آن‌ها مربوط به تجزیه و تحلیل محتوا و ساختار پیام‌ها و چگونگی شکل‌گیری موج‌های اعتراضی در توپیتر بود. ایراد اصلی مدل پیشنهادی آن‌ها در مرحله استخراج نهایی است جایی که سامانه آن‌ها تنها قادر است تعداد محدودی از اطلاعات از قبل تعیین شده را کشف کند و پویایی لازم برای دریافت اطلاعات متنوع و جدید را ندارد.

تجزیه و تحلیل احساسات و طبقه‌بندی اعتراض کشاورزان هندی با استفاده از داده‌های توپیتر [۶]، داده‌هایی را از توپیتر در مورد اعتراض کشاورزان جمع‌آوری کردند تا احساساتی را که مردم در سطح بین‌المللی به اشتراک می‌گذارند درک کنند. آن‌ها از مدل‌هایی برای دسته‌بندی و تجزیه و تحلیل احساسات بر اساس مجموعه‌ای حدود ۲۰۰۰۰ توپیت در استفاده کردند. آن‌ها تجزیه و تحلیل خود را با استفاده از Bag of Words و TF-IDF انجام دادند و متوجه شدند که Bag of Words بهتر از TF-IDF عمل می‌کند. علاوه بر این، از Decision Trees، Naive Bayes، Random Forests و Support Vector Machines استفاده کردند و متوجه شدند که Random Forest بالاترین دقت طبقه‌بندی را دارد.

توپیتر برای امدادسانی به بلایا از طریق تجزیه و تحلیل احساسات برای Covid-19 و بحران‌های خطر طبیعی [۷]، مدل پرسپترون چند لایه را برای طبقه‌بندی توپیت‌ها در هنگام فاجعه بر اساس نیاز منابع، در دسترس بودن منابع و موارد دیگر تعریف کرده است. پس از پیش‌پردازش کافی، توپیت‌ها با استفاده از جاسازی کلمه‌ای خاص برای فاجعه از پیش آموزش دیده، بردار شدند. مجموعه داده‌های عمومی زلزله نیپال (۲۰۱۵) و زلزله ایتالیا (۲۰۱۶) با استفاده از فراوانی کلمه تجزیه و تحلیل شد و برای آموزش مدل و اعتبارسنجی استفاده شد. مدل پیشنهادی نتایج بهتری را در تمام موارد آزمایش نشان داد و ثابت کرده است که برای داده‌های یک فاجعه در آینده قابل استفاده است. محدودیت روش پیشنهادی این است که دقت طبقه‌بندی آن به شدت به نوع منبع مورد استفاده بستگی دارد.

شبکه‌های عصبی کانولوشن عمیق برای تحلیل احساسات توپیتر [۸]، از یک شبکه عصبی کانولوشن برای طبقه‌بندی احساسات توپیتر استفاده کردند. مدل آن‌ها اطلاعات متنی را با ساختار تکرار شونده می‌گیرد و نمایش متن را با استفاده از یک شبکه عصبی کانولوشن می‌سازد. آن‌ها نتایج تجربی خود را در پنج مجموعه داده گزارش کردند. نتایج نشان داد این مدل بهتر از رویکردهای پیشرفته و مدل پایه عمل می‌کند. درنهایت می‌توان نتیجه گرفت که شبکه عصبی کانولوشن عمیق با استفاده از

سامانه روزانه تعداد پست‌هایی که درباره چند هشتگ مخرب است را شمارش می‌کنیم، هر گاه تعداد این پست‌ها از یک مقدار آستانه عبور کرد، به‌عنوان یک سیگنال جدید و مخرب تلقی می‌کنیم.

اما ممکن است در برخی از ناآرامی‌ها کاربران از یک شعار جدید برای بیان اعتراضات استفاده کنند. برای مثال #هفت\_تپه یکی از هشتگ‌های جدیدی بود که در یکی از ناآرامی‌های اخیر مورد استفاده قرار گرفت. برای حل این مشکل نیاز به یک ابزار جدید داریم تا بتواند مکمل روش قبلی برای شناسایی سیگنال‌های جدید باشد. ما در چارچوب خود از یک مدل تشخیص احساس به‌منظور شناسایی احساس نارضایتی در متن است استفاده می‌کنیم تا بتوانیم با اطمینان بالاتری ناآرامی‌ها را شناسایی کنیم (DD<sup>1</sup>). در قسمت‌های بعدی مقاله درباره چگونگی عملکرد این سامانه و مراحل طراحی آن بیشتر بحث می‌کنیم.


جدول (۱): هشتگ‌های پرستفاده در ناآرامی‌های اخیر ایران

براندازی	آشوب	اشغال	انتخابات-ایران
اعتراض	اعتراض_سراسری	تظاهرات_سراسری	تظاهرات
اغتشاش	بتزین	گرانی_بتزین	شورش
سهمیه_بندی_بتزین	اعتصاب	نه_به_گرانی	فساد
تقلب	تقلب_بزرگ	کودتا	جنبش
آبان_۹۸	دی_۹۶	خرداد_۸۸	تجمع
قیام	جنبش_سبز	گرانی_مرغ	قطعی_برق
گرانی_خودرو	بورس	قطعی_آب	آلودگی_هوا
زمین_خواری	اختلاس	رانت	رشوه

پس از جداسازی متون نارضایتی از سروصداها، در مرحله بعدی با یک ابزار تشخیص موضوع تلاش می‌کنیم تا موضوع اصلی این تحرکات را شناسایی کنیم. همچنین در این مرحله هشتگ‌های اصلی اعتراض استخراج می‌شود تا عملیات جمع‌آوری داده‌های جدید با سرعت بالاتری انجام شود (TD<sup>2</sup>). در ادامه مقاله شرح کاملی از این ابزار ارائه می‌دهیم.

اکنون که موضوع و هشتگ‌های اصلی شناسایی شد، قدم بعدی جمع‌آوری داده‌های جدید بر اساس موضوع و یا هشتگ کشف شده در مرحله قبلی است. این داده‌های جدید پس از عمل پیش‌پردازش (مشابه عمل پیش‌پردازش در DD) در یک پایگاه داده ذخیره می‌شود تا در مرحله بعدی به‌عنوان ورودی به مدل تجزیه و تحلیل ناآرامی داده شود.

همان‌طور که در این نمودار مشاهده می‌کنید سامانه پیش‌بینی ناآرامی ما در هر لحظه قادر به شناسایی تحرکات شبکه است. تحرک به معنی افزایش حجم داده‌های مرتبط با یک موضوع در یک زمان مشخص (مثلاً ۲۴ ساعت) است که این بازه زمانی می‌تواند در مواقع حساس تر مقدار کمتری داشته باشد. این تحرکات که در اصطلاح ترندهای شبکه نام دارد در ساعت‌هایی خاص از شبانه‌روز به وسیله کاربران در رسانه‌های اجتماعی نمایان می‌شوند. سامانه با استفاده از API‌هایی که این شبکه‌های اجتماعی در اختیار توسعه دهندگان قرار می‌دهند قادر به رصد لحظه به لحظه تحرکات شبکه است. از آنجایی که شبکه اجتماعی تویتر دسترسی‌های بیشتری را در این مورد در اختیار کاربران قرار می‌دهد، ما در این تحقیق از API تویتر استفاده کرده‌ایم.



شکل (۱): نمودار جریان و سیکل چارچوب پیشنهادی

از آنجایی که روزانه در شبکه‌های اجتماعی شاهد ترند شدن موضوعات مختلف هستیم (برای مثال بازنشر فراوان یک شایعه و یا یک کلیپ و موضوع طنز) قدم دوم در شناسایی سیگنال‌های اولیه است. با توجه به اینکه در شبکه‌های اجتماعی روزانه تحرکات زیادی مشاهده می‌شود، سامانه ما باید قادر به تشخیص ترندهایی باشد که مربوط به ناآرامی‌ها و بیان اعتراضات کاربران باشد چرا که دیگر تحرکات از نظر سامانه سروصداهای اضافی تلقی می‌شود که کاربردی ندارد.

یکی از روش‌های رایج برای شناسایی سیگنال‌های اولیه، استفاده از هشتگ‌های خاصی است که در اکثر ناآرامی‌ها مورد استفاده قرار می‌گیرد جدول (۱) تعدادی از این هشتگ‌ها که در اکثر ناآرامی‌های اخیر مورد استفاده بوده است را نشان می‌دهد.

<sup>1</sup> Dissatisfaction Detection Model

<sup>2</sup> Topic Detection Model

#### ۴-۱-۲- پیش پردازش داده‌ها

داده‌های استخراج شده از شبکه‌های اجتماعی اغلب دارای قطبیت و بسیار حساس به ناسازگاری و افزونگی هستند چرا که اغلب توسط کاربران نوشته شده و ممکن است بارها نسخه‌هایی از آن‌ها در رسانه‌های مختلف بازرسال و ویرایش شده باشد. به همین دلیل این داده‌ها نیاز به پیش‌پردازش‌هایی به‌منظور استانداردسازی دارند. پیش‌پردازش این متون شامل موارد زیر است:

- حذف تمامی آدرس‌ها (برای مثال: www.xyz.com)، هشتگ‌های اضافی (#) و اهداف (@rasool)؛
- تصحیح غلط‌های املایی؛
- جایگزینی تمامی شکلک‌ها با احساسات آن‌ها؛
- حذف تمامی اعداد، نمادها و نشانه‌گذاری‌ها؛
- گسترش کلمات اختصاری (با استفاده از فرهنگ لغت)؛
- حذف کلماتی که به زبان‌های دیگر نوشته شده است؛
- حذف متونی که کمتر از ۳ کلمه هستند؛
- حذف متونی که شامل تکرار یک کلمه هستند.

#### ۴-۱-۳- استخراج ویژگی

مجموعه داده پیش‌پردازش شده دارای ویژگی‌های متمایز بسیاری است. در روش استخراج ویژگی، ما جنبه‌هایی را از مجموعه داده پردازش شده استخراج می‌کنیم. بعداً از این جنبه برای محاسبه قطبیت مثبت و منفی در جمله‌ای استفاده می‌کنیم که برای تعیین میزان نارضایتی افراد مفید است. در مقاله تجزیه و تحلیل احساسات داده‌های توییتر [۱۰] برخی از نمونه ویژگی‌ها گزارش شده‌اند که عبارتند از:

- استفاده از فرکانس کلمات در متن؛
- برچسب‌گذاری بخش‌هایی از کلام؛
- کلمات و عبارات عقیدتی که بیانگر یک حس هستند؛
- نفی و انکار در متن؛
- موقعیت اصطلاحات در متن که می‌تواند در احساس عمومی متن تأثیر بگذارد؛
- استفاده از الگوهای نحوی.

#### ۴-۱-۴- آموزش و طبقه‌بندی

برای آموزش و ساخت مدل خود از ابزار Monkey learn Sentiment Analysis استفاده کردیم. این ابزار این امکان را به ما

مدل استخراج اطلاعات (IE<sup>1</sup>) ابزار بعدی در این سامانه است که وظیفه آن تجزیه و تحلیل انبوهی از داده‌های جدید است تا اطلاعات ارزشمند از میان آن‌ها استخراج شود. این مرحله به‌عنوان مهم‌ترین گام در پیش‌بینی است که در قسمت‌های بعدی آن را شرح می‌دهیم.

گام طبیعی بعدی خلاصه کردن و نمایش خودکار موضوعات مورد بحث به‌منظور قابل تفسیر بودن خروجی برای سیاست‌گذاران و تصمیم‌گیرندگان است. در ادامه به شرح و تفسیر هر یک از قسمت‌های بالا می‌پردازیم و چگونگی طراحی و پیاده‌سازی هر قسمت را شرح می‌دهیم.

#### ۴-۱-۴- مدل DD تشخیص احساس نارضایتی

تجزیه و تحلیل احساسات می‌تواند به‌عنوان فرآیندی تعریف شود که استخراج نگرش‌ها، نظرات، دیدگاه‌ها و احساسات متن، گفتار، توییت‌ها و منابع پایگاه داده را از طریق پردازش زبان طبیعی (NLP) به‌صورت خودکار انجام دهد. تجزیه و تحلیل احساسات شامل طبقه‌بندی نظرات در متن به دسته‌هایی مانند "مثبت" یا "منفی" یا "خنثی" است. همچنین از آن به‌عنوان تجزیه و تحلیل ذهنیت، استخراج نظر یاد می‌شود [۱۰].

رویکرد ما در این چارچوب درک احساس نارضایتی در متن است. برای رسیدن به این نتیجه ما دو احساس را تعریف می‌کنیم و تلاش می‌کنیم تا متون را در یکی از این دو دسته‌بندی قرار دهیم. دسته اول مربوط به احساس نارضایتی است که ترکیبی از احساس ناراحتی، منفی، خشم و پرخاشگری است. دسته دوم شامل دیگر احساسات است که به دلیل عدم نیاز از سامانه ما خارج شده و نادیده گرفته می‌شوند. در ادامه به بررسی چگونگی ساخت این مدل می‌پردازیم.

#### ۴-۱-۴- آماده‌سازی داده‌ها

در حال حاضر شبکه‌های اجتماعی اینستاگرام و واتساپ پرمخاطب‌ترین رسانه در بین کاربران فارسی زبان است اما با توجه به اینکه دسترسی به API این شبکه‌ها امکان‌پذیر نیست، ناچار به استفاده از روش‌های دیگر هستیم. ما با استفاده از ابزار OctaParse تعداد ۸۰۰ توییت را که دارای هشتگ‌های نارضایتی بود جمع‌آوری کردیم. اما برای آموزش مدل خود نیاز به توییت‌هایی در موضوعات دیگر نیز بودیم، برای این منظور از دیتاست آماده ۱۳۰ هزار توییت استفاده کردیم که شامل موضوعاتی خبری، طنز و دیگر موضوعات است. برای دسترسی لینک هر دو دیتاست در قسمت مراجع قرار داده شده است [۱۱].

<sup>1</sup> Information Extraction Mode

## جدول (۲): میزان دقت مدل DD در تفکیک

داده‌های ناراضیاتی از داده‌های بی‌ارزش

	Dissatisfaction	Other
Num of Texts	۴۴	۵۷
Precision	٪۶۹	٪۷۵
Recall	٪۶۶	٪۷۷
True Positive	۲۹	۴۴
True Negative	۴۴	۲۹
False Positive	۱۳	۱۵
False Negative	۱۵	۱۳

## ۴-۲- مدل TD تشخیص موضوع و هشتم‌های اصلی

مدل‌سازی موضوع یک روش یادگیری ماشین بدون نظارت است که قادر به اسکن مجموعه‌ای از اسناد، تشخیص الگوهای کلمات و عبارات در آن‌ها و خوشه‌بندی خودکار گروه‌های کلمه‌ای و اصطلاحات مشابه است که مجموعه اسناد را به بهترین شکل مشخص می‌کند. مدل‌سازی موضوع شامل شمارش کلمات و گروه‌بندی الگوهای کلمه‌ای مشابه برای استنباط موضوعات در داده‌های بدون ساختار است [۱۳].

از مهم‌ترین روش‌های مدل‌سازی متن می‌توان به تحلیل معنایی نهفته (LSA<sup>۲</sup>) و تخصیص پنهان دیریکله (LDA<sup>۳</sup>) اشاره کرد. ما در سامانه خود از LDA برای استخراج موضوع استفاده کردیم. مقاله "موضوعات اصلی را از مجموعه داده خود با استفاده از LDA در چند دقیقه استخراج کنید" [۱۴] شرح کاملی از چگونگی استفاده از این روش را ارائه کرده است. مراحل پیاده‌سازی این روش به شرح زیر است:

- توکن‌بندی: متن را به جملات و جملات را به کلمات تقسیم کرده سپس کلمات را کوچک کرده و علائم نگارشی را حذف می‌کنیم.
- کلماتی که کمتر از ۳ حرف دارند حذف می‌شوند.
- تمام ایست و اژه‌ها حذف می‌شوند.
- کلمات لماتیزه می‌شوند: کلمات در شخص سوم به اول شخص و افعال در زمان گذشته و آینده به حال تبدیل می‌شوند.

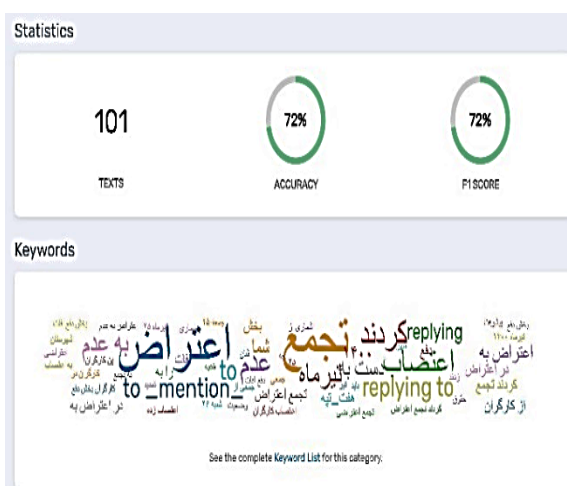
می‌دهد تا با استفاده دو روش Naïve Bayes و SVM<sup>۱</sup> مدل خود را برای استخراج احساس ساخته و با استفاده از دسترسی‌هایی که در اختیار ما قرار می‌دهد در هر محیطی از آن مدل استفاده کنیم [۱۲].

در این مدل دو احساس "ناراضیاتی" و "دیگر" را تعریف کردیم و سپس تعداد ۲۰۰۰ توییت از مجموعه داده خود را به‌عنوان ورودی به سامانه وارد کردیم و از تعدادی از کاربران به‌منظور برچسب‌گذاری دستی این داده‌ها در دو دسته‌بندی کمک گرفتیم.

پس از گذشت ۱۰۰ مرحله از آموزش شاهد نتایج اولیه مدل بودیم. در شکل‌های (۲ و ۳) و همچنین جدول (۲) چگونگی انجام این برچسب‌گذاری را به همراه کلید واژه‌های اصلی استخراج شده و دقت مدل مشاهده می‌کنید.



شکل (۲): برچسب‌گذاری دستی توییت‌های ورودی



شکل (۳): کلید واژه‌های اصلی مدل استخراج ویژگی به همراه میزان قابلیت اطمینان مدل

<sup>۲</sup> Latent Semantic Analysis<sup>۳</sup> Latent Dirichlet Allocation<sup>۱</sup> Support Vector Machines

ما از ابزار MonkeyLearn Extractor برای استخراج اطلاعات بالا استفاده کردیم. به‌طور کلی پنج مشخصه مکانی، زمانی، اهداف، شخصیت و نقش اجتماعی را تعریف کردیم و از تعدادی از همراهان برای آموزش ۸۰۰ توییت در این مدل کمک گرفتیم.

شکل (۴) فرآیند استخراج اطلاعات از یک توییت به کمک این مدل را نشان می‌دهد. همان‌طور که مشاهده می‌شود مدل عباراتی همچون "امروز" و "سومین روز متوالی" را به‌عنوان موضوعاتی که نشان‌دهنده زمان است استخراج کرده است. همچنین "محوطه شرکت" به‌عنوان یک مشخصه که نشان‌دهنده مکان است تفکیک شده است.

مدل همچنین قادر به تشخیص موضوعات مختلفی است که می‌توانند از اهداف یک ناآرامی باشند. برای مثال عبارات "هفت‌تپه" و "پرداخت حقوق معوقه" در این دسته‌بندی قرار گرفته است. علاوه بر این مدل IE توانایی تشخیص اسامی اشخاص و نقش اجتماعی آن‌ها در جامعه است. برای مثال کلمه "کارگر" به‌عنوان نقش اجتماعی اهداف استخراج شده است.

بعد از گذشت ۵۰ مرحله از فرآیند آموزش به نتایج امیدبخشی در مدل استخراج ویژگی خود دست یافتیم که در شکل (۵) و جدول (۳) مشاهده می‌کنید.

- کلمات به شکل ریشه‌ای خود کاهش می‌یابند.

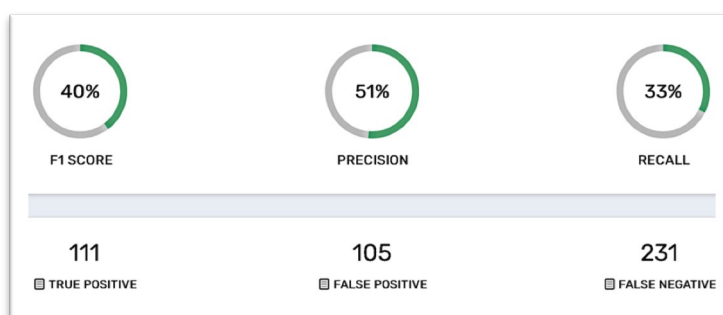
#### ۳-۴- مدل IE برای تحلیل ناآرامی‌ها

استخراج اطلاعات (IE) یک فرآیند استخراج خودکار برای تولید داده‌های ساخت یافته از مجموعه اسناد بدون ساختار یا نیمه ساختاری است [۱۵]. به‌طور کلی هدف این مدل در چارچوب پیشنهادی ما دریافت اطلاعات سودمند از داده‌های فراوانی است که به کمک سیگنال کشف شده جمع‌آوری می‌شود. این اطلاعات شامل موارد زیر است:

- اطلاعات شخصی: از جمله ویژگی‌های جمعیت شناختی مانند سن، جنسیت، قومیت و آدرس افرادی که در این تنش و ناآرامی شرکت کرده‌اند؛
- اطلاعات زمانی و مکانی: تشخیص و پیش‌بینی مکان‌هایی که احتمال ناآرامی‌های بیشتر را دارند. همچنین پیش‌بینی زمان بروز ناآرامی‌ها؛
- اطلاعات ماهیتی به‌منظور کشف دلایل مختلف ناآرامی‌ها و همچنین رابطه اقدامات انجام شده و تأثیر آن در شدت ناآرامی؛
- اسامی شخصیت‌های معروف.

The screenshot shows the MonkeyLearn Extractor interface. On the left, a tweet is displayed with various entities highlighted and labeled with tags like 'TARGETS', 'TIME', 'CORTEX OF SOCIETY', and 'PLACE'. On the right, a 'TAGS' sidebar lists categories such as 'Place', 'Time', 'Targets', 'Cortex of society', and 'Character', with 'Targets' selected.

شکل (۴): آموزش دستی توییت‌های ورودی برای مدل استخراج اطلاعات



شکل (۵): دقت مدل استخراج اطلاعات IE



جدول (۳): میزان دقت مدل IE در استخراج موضوعات، پس از گذشت ۵۰ مرحله (به تفکیک هر موضوع)

	Place	Time	Target	C-S	Char
F1Score	٪۱۵	٪۲۸	٪۵۱	۰	٪۵
Precision	٪۲۹	٪۴۱	٪۵۶	۰	٪۲۰
Recall	٪۱۰	٪۲۱	٪۴۸	۰	٪۳
True Positive	۵	۷	۹۸	۰	۱
False Positive	۱۲	۱۰	۷۸	۱	۴
False Negative	۴۴	۲۶	۱۰۸	۱۷	۳۷

$$Precision = \frac{TP}{TP + FP} \quad (۲)$$

معیار Recall معیار کامل بودن است که نشان می‌دهد چند درصد از نقاط داده مثبت را طبقه‌بندی کننده به‌عنوان مثبت برچسب‌گذاری کرد [۱۷].

$$Recall = \frac{TP}{TP + FN} \quad (۳)$$

برای یک مدل امتیاز (F1 Score) میانگین هارمونیک Precision و Recall است. میانگین هارمونیک راهی است برای یافتن میانگین در حالی که به همه اعداد وزن برابر داده‌ایم [۱۶].

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (۴)$$

برای ارزیابی چارچوب پیشنهادی از روش Cross-Validation استفاده کردیم. به این ترتیب مجموعه داده خود که شامل ۱۳۰ هزار تویت بود را در چهار مرحله به قسمت‌های مختلف تقسیم کردیم و قسمتی از آن را برای آموزش سامانه و قسمت باقی‌مانده را برای ارزیابی میزان اثربخشی سامانه مورد استفاده قرار دادیم. شکل (۶) نمونه‌ای از تقسیم‌بندی Cross-Validation را نشان می‌دهد.

شکل (۶): مراحل عملیات Cross Validation<sup>۱</sup>

نتایج نشان داد که علاوه بر افزایش دقت سامانه مدل توانایی

## ۵- ارزیابی چارچوب پیشنهادی

پس از آماده شدن یک مدل، ارزیابی عملکرد آن ضروری است. این به این دلیل است که بدون محک زدن آن، نمی‌توانیم از عملکرد خوب یا بد آن مطمئن باشیم. توصیه نمی‌شود که یک مدل بدون ارزیابی کارایی آن به تولید برسد [۱۶]. روش‌های مختلفی برای ارزیابی عملکرد یک مدل وجود دارد که بر اساس ۴ معیار اصلی محاسبه می‌شوند. این معیارها عبارتند از:


- مثبت واقعی (TP): این یک نقطه داده است که توسط طبقه‌بندی کننده به‌عنوان A برچسب‌گذاری شده است و در واقع از کلاس A است [۱۷].
- منفی واقعی (TN): مواردی هستند که منفی پیش‌بینی می‌شوند و در واقع در کلاس منفی [۱۸].
- مثبت کاذب (FP): نمونه‌هایی هستند که به‌عنوان مثبت پیش‌بینی می‌شوند اما در واقع در کلاس مثبت نیستند. این‌ها نویزهایی در پیش‌بینی هستند [۱۸].
- منفی کاذب (FN): از سوی دیگر، منفی‌های کاذب (FN) نمونه‌هایی هستند که منفی پیش‌بینی می‌شوند اما در واقع در کلاس مثبت هستند [۱۸].

دقت (Accuracy) به‌عنوان نسبت نمونه‌های به درستی طبقه‌بندی شده به تعداد کل نمونه‌ها تعریف می‌شود. هر زمان که از دقت برای ارزیابی مدل استفاده می‌شود، باید اطمینان حاصل کنیم که داده‌ها از نظر کلاس‌ها متعادل هستند، به این معنی که باید تعداد نمونه‌های تقریباً برابری از هر کلاس داشته باشیم [۱۲].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۱)$$

معیار Precision نشان می‌دهد که چند درصد از نقاط داده طبقه‌بندی کننده به‌عنوان مثبت برچسب‌گذاری شده و در واقع مثبت هستند [۱۵].

<sup>۱</sup> <https://www.mathworks.com/discovery/cross-validation.html>

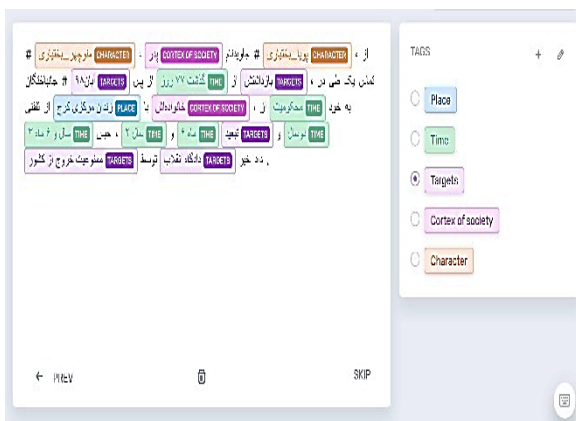


شکل (۹): نتایج مدل DD که مربوط به دسته ناراضیاتی (Dissatisfaction) است، به همراه کلمات کلیدی کشف شده

همچنین با افزایش مراحل یادگیری در مدل IE شاهد افزایش دقت این مدل تا ۴۰ درصد نیز بودیم. در جدول (۴) مقادیر مربوط به مدل IE به تفکیک هر یک از برچسب‌ها را مشاهده می‌کنید. همان‌طور که در شکل (۱۰) نیز مشاهده می‌شود، مدل IE موفق به استخراج اطلاعات در ۵ موضوع مختلف شده است.

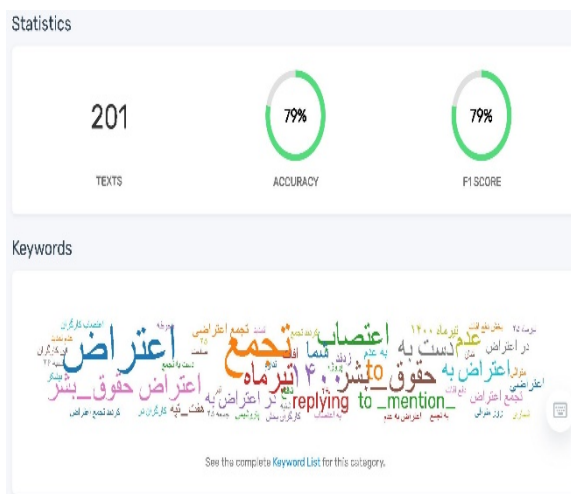
جدول (۴): دقت مدل IE به تفکیک هر موضوع

	Overall	Place	Time	Target	C-S	Char
<b>F1Score</b>	٪۴۰	٪۲۴	٪۲۹	٪۵۲	۰	٪۱۰
<b>Precision</b>	٪۴۷	٪۳۷	٪۴۷	٪۵۸	۰	٪۲۳
<b>Recall</b>	٪۳۴	٪۱۹	٪۲۱	٪۵۰	۰	٪۶
<b>True Positive</b>	۱۶۸	۱۳	۱۰	۱۴۲	۰	۳
<b>False Positive</b>	۱۸۸	۲۲	۱۷	۱۹۲	۱۰	۱۰
<b>False Negative</b>	۳۲۳	۵۵	۳۷	۱۵۶	۳۰	۴۵

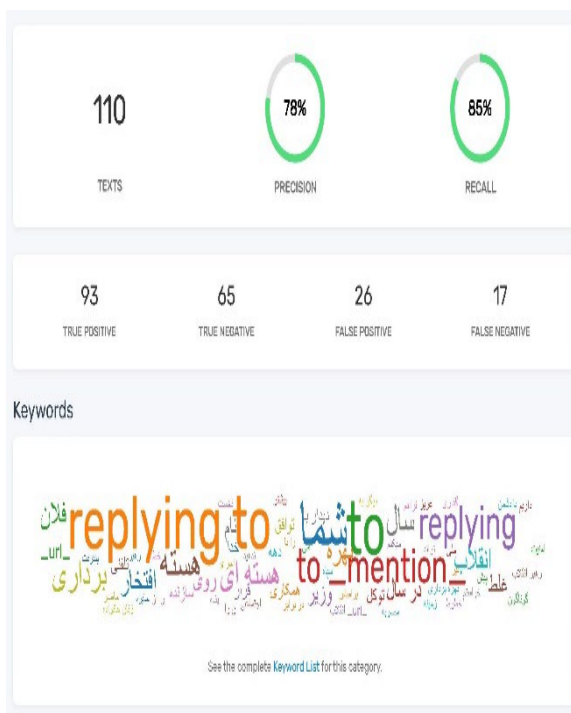


شکل (۱۰): چگونگی استخراج و تشخیص موضوعات در متن توسط مدل IE

نادیده گرفتن برخی از متون که دارای محدودیت است را دارد، برای مثال جملات کوتاه کنار گذاشته می‌شود و همچنین پیام‌هایی که تنها شامل پیوندها و اشاره به اکانت‌های دیگر هستند مورد ارزیابی سامانه قرار نمی‌گرفت. در شکل (۷) نتایج کلی به‌دست آمده از مدل DD را مشاهده می‌کنید. مدل در این حالت موفق شد با دقت ۷۹ درصد داده‌هایی را که بار ناراضیاتی داشته‌اند، از توییتهای و داده‌های معمولی جدا کند. شکل‌های (۸ و ۹) نتایج مدل DD را به تفکیک هر یک از دسته‌ها نشان می‌دهد.



شکل (۷): نتایج کلی (Overall) به‌دست آمده از مدل DD به همراه اصلی‌ترین کلمات کلیدی کشف شده



شکل (۸): نتایج مدل DD که مربوط به دسته سروصدا یا متون بی‌ارزش است، به همراه کلمات کلیدی کشف شده

## ۷- منابع

- [1] M. Bahrami, Y. Findik, B. Bozkaya, and S. Balcisoy, "Twitter Reveals: Using Twitter Analytics to Predict Public Protests," Mit Media Lab, Massachusetts Institute of Technology, Cambridge, Ma, Usa, 2017.
- [2] میرزایی، میثم، مروری بر روش‌های تشخیص ناهنجاری مبتنی بر گراف در شبکه‌های اجتماعی، نشریه پدافند غیرعامل، دوره ۱۰، شماره ۳، شماره پیاپی ۳۹، صفحه ۱۳-۱۰، پاییز ۱۳۹۸
- [3] N. Alsaedi, P. Burnap, and O. Rana, "Can We Predict a Riot? Disruptive Event Detection Using Twitter," Cardiff University, Uk, 2017.
- [4] L. Dwarakanath, A. Kamsin, R. A. Rasheed, A. Anandhan, and L. Shuib, "Automated Machine Learning Approaches for Emergency Response and Coordination via Social Media in the Aftermath of a Disaster: A Review," Department of Computer System And Technology, Faculty Of Computer Science and Information Technology, University of Malaya, Kuala Lumpur 50603, 2021.
- [5] K. Bajpai and A. Jaiswal, "A Framework for Analyzing Collective Action Events on Twitter," Pennsylvania State University, 2011.
- [6] A. S. Neogi, K. A. Garga, R. K. Mishraa, and Y.K. Dwivedi, "Sentiment Analysis and Classification of Indian Farmers' Protest Using Twitter Data," Department of Computer Science, BITS Pilani, Dubai Campus, Dubai, United Arab Emirates, 2021.
- [7] S. Behl, A. Rao, S Aggarwal, S Chadha, and H.S. Pannu, "Twitter for Disaster Relief through Sentiment Analysis for COVID-19 and Natural Hazard Crises," Computer Science and Engineering Department Thapar Institute of Engineering and Technology Patiala India, India, 2021.
- [8] Z. Jianqiang, G. Xiaolin, and A. Z. Xuejun, "Deep Convolution Neural Networks for Twitter Sentiment Analysis," School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China, 2018.
- [9] Z. Jianqiang and A. G. Xiaolin, "Comparison Research on Text Pre-processing Methods on Twitter Sentiment Analysis," School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China, 2017.
- [10] V. A. Kharde and S.S. Sonawane, "Sentiment Analysis of Twitter Data: A Survey of Techniques," Department of Computer Engg,

ارزیابی‌های ما نشان می‌دهد که برای داشتن سامانه کارآمد نیاز به آموزش بیشتر وجود دارد چرا که با تمام معیارهایی که از ناآرامی‌های گذشته دریافت کرده‌ایم باز هم عمل پیش‌بینی یک فرآیند پیچیده و متغیر است. به همین دلیل سامانه ما نیاز به آموزش با داده‌های بیشتر در زمینه‌های مختلف از نارضایتی را دارد تا بتواند در آینده به‌عنوان یک سامانه قابل اطمینان در شرایط بحرانی مورد استفاده قرار گیرد.

## ۶- نتیجه‌گیری

در این مطالعه ما یک چارچوب تشخیص و پیش‌بینی ناآرامی‌ها را با استفاده از داده‌های موجود در شبکه‌های اجتماعی ارائه دادیم. ما از روش‌های مختلفی که در یادگیری ماشین و پردازش زبان طبیعی مورد استفاده قرار می‌گیرند استفاده کردیم. برای مثال از تحلیل احساس برای تشخیص احساس نارضایتی به‌منظور کشف سیگنال‌های اولیه ناآرامی‌ها استفاده کردیم، سپس از ابزارهای تحلیل موضوع برای درک موضوع اصلی این سیگنال‌ها و استخراج هشنگ‌های اصلی استفاده کردیم. درنهایت به کمک روش‌های استخراج اطلاعات تلاش کردیم اطلاعات سودمندی را برای پیش‌بینی ناآرامی‌ها استخراج کنیم تا درنهایت بتوانیم به هدف اصلی خود یعنی تشخیص نارضایتی و شدت‌های مختلف آن مانند اغتشاش، ناآرامی، هرج و مرج و غیره را تشخیص دهیم. برای آموزش مدل خود از ابزار MonkeyLearn استفاده کردیم که عمل یادگیری را با هر دو روش SVM و NaiveBayes برای ما فراهم می‌کند. به‌منظور ارزیابی سامانه خود از شبکه اجتماعی توییتر استفاده کردیم و مجموعه ۱۳۰ هزار توییت که مربوط به ناآرامی‌های اخیر ایران بود را به کمک ابزار OctoParse جمع‌آوری کردیم و درنهایت چارچوب خود را با این مجموعه داده از قبل جمع‌آوری شده ارزیابی کردیم. مشاهده کردیم که چارچوب پیشنهادی با دقت ۷۹ درصد توانایی تشخیص توییت‌های نارضایتی را دارد. همچنین موفق به استخراج اطلاعات مفید از این توییت‌ها در غالب ۵ موضوع شدیم که با دقت ۴۰ درصد اطلاعاتی شامل مکان، زمان، اشخاص، اهداف و عوامل مرتبط با یک رویداد را استخراج کرد.

برای کارهای آینده رویکردهای زیادی وجود دارد. یکی از اصلی‌ترین دستورات عمل‌ها، بهبود روند تشخیص و ابهام‌زدایی برای رویدادهای در مقیاس کوچک است. هدف دیگر می‌تواند افزایش قابلیت تعمیم برای محیط‌های مختلف باشد تا بتوان سامانه خود را در رسانه‌های مختلف پیاده‌سازی کرده و نتایج جامع‌تری را دست آوریم.

- [15] W. Hua, D. T. Huynh , S. Hosseini , J. Lu, and X. Zhou, “Information Extraction From Microblogs A Survey”:Int. J. Softw. Informatics 6 (4), 495-522, 2012.
- [16] Ch. Rohan, “The Natural Language Processing Workshop,” Packt Publishing, 2020.
- [17] Th. Jalaj, “Python Natural Language Processing,” Packt Publishing, 2017.
- [18] H. Masato, “Real-World Natural Language Processing,” Manning Shelter Island, 2021.
- Pune Institute of Computer Technology,Pune University of Pune (India), 2016.
- [11] R. Abbasi, <http://ideasaryan.blogfa.com/category/3>, 2021.
- [12] M. Learn, <https://monkeylearn.com/text-classification>, 2019.
- [13] F. Pascual, <https://monkeylearn.com/blog/introduction-to-topic-modeling>, 2019.
- [14] P. Dwivedi, “NLP: Extracting the Main Topics from your Dataset Using LDA in Minutes, 2018.