

Paper Type: Original Article



# Developing Clinical Decision Support Systems in Psychiatry Using Microblogging Data

Ramin Safa<sup>1</sup> , Peyman Bayat<sup>1,\*</sup> , Leila Moghtader<sup>2</sup> 

<sup>1</sup> Department of Computer Engineering, Rasht Branch, Islamic Azad University, Rasht, Iran; r.safa@outlook.com; bayat@iaurasht.ac.ir.

<sup>2</sup> Department of Psychology, Rasht Branch, Islamic Azad University, Rasht, Iran; moghtaderleila@yahoo.com.

## Citation:



Safa, R., Bayat, P., & Moghtader, L. (2022). Developing clinical decision support systems in psychiatry using microblogging data. *Journal of decisions and operations research*, 7(2), 259-276.

Received: 15/02/2022

Reviewed: 27/03/2022

Revised: 21/04/2022

Accepted: 29/05/2022

## Abstract

**Purpose:** While diagnosing mental disorders in traditional approaches relies on questionnaires, interviews, and clinical trials, automated screening tools can take a shorter path. These tools can be developed as innovative evaluation techniques, decision support systems, and prevention strategies to help susceptible individuals. Due to the tendency of people to share thoughts and feelings on social platforms, microblogging data contains valuable information that can be analyzed to identify users' mental states. This study describes a roadmap for data analysis in the field in question.

**Methodology:** In the first part of this paper, concepts such as electronic mental health and microblogging platforms are introduced. And their conceptual relationship is discussed by providing explanations about data science and social data analysis. Next, the prediction of disorder in social platforms is described separately. Finally, by reviewing related works and open issues, we explain how data collection, pre-processing, and analysis are done using different features of real-world data.

**Findings:** By experimental analysis, this study shows that the extracted features from the users' profiles have a significant effect on predicting mental health symptoms, and even with the information extracted from the users' public profiles, the mental state can be predicted with reasonable accuracy.

**Originality/Value:** In this study, automatic analysis of social data to investigate the psychological signals is described, and in the implementation section, it is founded that the symptoms can be followed in almost all the studied features.

**Keywords:** Social network analysis, Electronic mental health, Clinical decision support systems.

Corresponding Author: bayat@iaurasht.ac.ir

 <https://dorl.net/dor/20.1001.1.25385097.1401.7.2.4.1>



Licensee. **Journal of Decisions and Operations Research**. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0>).



## توسعه سیستم‌های پشتیبان تصمیم‌بالینی در روانپزشکی با استفاده از داده‌های میکرو بلاگینگ

رامین صفا<sup>۱</sup>، پیمان بیات<sup>۱</sup>، لیلا مقتدر<sup>۲</sup>

<sup>۱</sup> گروه مهندسی کامپیوتر، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران.  
<sup>۲</sup> گروه روانشناسی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران.

### چکیده

**هدف:** روند تشخیص اختلال روانی در رویکردهای سنتی، متکی بر پرسشنامه، مصاحبه و بررسی‌های بالینی است؛ درحالی‌که ابزارهای غربالگری خودکار می‌توانند مسیر کوتاه‌تری را طی کنند و به‌عنوان استراتژی‌های ارزیابی نوین، سیستم‌های پشتیبان تصمیم و راهبردهای پیشگیری برای کمک به افراد مستعد توسعه یابند. با توجه به تمایل افراد به اشتراک‌گذاری افکار و احساسات در سکوها اجتماعی، داده‌های میکرو بلاگینگ حاوی اطلاعات ارزشمندی هستند که می‌توانند برای شناسایی حالات روانی مورد تحلیل قرار گیرند. هدف از این پژوهش تشریح سازوکار تحلیل داده در زمینه مورد بحث است.

**روش‌شناسی پژوهش:** در این مقاله، در ابتدا مفاهیمی مانند سلامت روان الکترونیک و سکوها میکرو بلاگینگ معرفی شده و با ارائه توضیحاتی در خصوص علم داده و تحلیل داده اجتماعی، ارتباط مفاهیم با یکدیگر مورد بحث قرار می‌گیرد. در ادامه در قالب بخشی جداگانه، پیش‌بینی اختلال در شبکه‌های اجتماعی شرح داده می‌شود. در نهایت با بررسی سوابق تحقیق و مسائل باز، به چگونگی جمع‌آوری داده، پیش‌پردازش و روند استفاده از ویژگی‌های متفاوت به کمک ابزارهای تحلیل گوناگون می‌پردازیم.

**یافته‌ها:** این پژوهش با پیاده‌سازی نمونه‌ای کاربردی از تجزیه و تحلیل داده اجتماعی روی داده‌های دنیای واقعی نشان می‌دهد، ویژگی‌های استخراج شده از نمایه کاربر، تأثیر قابل توجهی در پیش‌بینی علائم افسردگی دارند و حتی می‌توان با اطلاعات استخراج شده از نمایه عمومی کاربر، وضعیت روانی را با دقتی مناسب پیش‌بینی نمود.

**اصالت/ارزش افزوده علمی:** در این پژوهش چگونگی تحلیل خودکار داده اجتماعی با هدف شناسایی اختلال روانی شرح داده شده و در پیاده‌سازی مشخص می‌شود که علائم تقریباً در تمام ویژگی‌های مورد مطالعه قابل پیگیری هستند.

کلیدواژه‌ها: تحلیل شبکه‌های اجتماعی، سلامت روان الکترونیک، سیستم‌های تصمیم‌یار بالینی.

### ۱- مقدمه

شناخت ویژگی‌های روانی افراد، نیازمند بررسی تعاملات و اطلاعاتی است که بیانگر ترجیحات و طرز تفکر آن‌ها باشند. از این رو در روش‌های سنتی مرسوم، علائم و ویژگی‌ها با مراجعه به متخصص و استفاده از پرسشنامه و یا مصاحبه آشکار می‌شوند؛ اما بر اساس تحقیقات انجام شده در حوزه سلامت روان، درصد بالایی از اختلالات درست تشخیص داده نشده و یا پنهان باقی می‌مانند که این موضوع

\* نویسنده مسئول

bayat@iaurasht.ac.ir

<https://dorl.net/dor/20.1001.1.25385097.1401.7.2.4.1>





می‌تواند منجر به آسیب‌های گوناگون شود. به گزارش سازمان بهداشت جهانی، بیش از ۲۸۰ میلیون نفر در جهان از افسردگی رنج می‌برند<sup>۱</sup> و یافته‌های اخیر حاکی از شیوع بالای مشکلات روانی در طی همه‌گیری کوید-۱۹ است (گانو و همکاران<sup>۲</sup>، ۲۰۲۰). در حالی که روش‌های درمانی شناخته‌شده‌ای وجود دارد، به دلیل عدم مراجعه به پزشک و یا خطا در تشخیص نوع اختلال، تنها درصد محدودی از افراد طرح‌های درمانی مناسب را دریافت می‌کنند (مارتینز کاستانو و همکاران<sup>۳</sup>، ۲۰۲۰). این در شرایطی است که فقدان درمان مناسب در اختلالی مانند افسردگی می‌تواند منجر به ناتوانی، دوره‌های روان‌پریشی، افکار خودآزاری و در موارد حاد، خودکشی شود. بر این مبنای، بدیهی است که استراتژی‌های جدید تشخیص، مداخله و پیشگیری برای به حداقل رساندن آسیب از اهمیت ویژه‌ای برخوردار هستند. بهره‌گیری از علم داده<sup>۴</sup> در این زمینه می‌تواند بسیار مؤثر باشد. تکنیک‌های یادگیری ماشین با کمک به محققان در این حوزه پژوهشی در استخراج اطلاعات از مجموعه داده‌های پیچیده نقشی کلیدی ایفا می‌کنند و در نهایت، توانمندسازی و تسهیل تصمیم‌گیری را به همراه خواهند داشت. از این تکنیک‌ها می‌توان برای تفسیر داده‌ها و ایجاد مدل‌های پیش‌بینی در حوزه‌های گوناگون، مانند امور مالی، اقتصاد، سیاست، صنعت، تشخیص جرم و کلاهبرداری استفاده نمود (وانکولپ و همکاران<sup>۵</sup>، ۲۰۱۷). به همین ترتیب رویکردهای علم داده به تحلیلگران علوم پزشکی اجازه می‌دهند تا مجموعه داده‌های عظیم حوزه مراقبت سلامت<sup>۶</sup> را به منظور شناسایی الگوها و دستیابی به دانش معنادار مطالعه کنند.

یکی از منابع ارزشمند داده، رسانه‌های اجتماعی هستند. در میان گونه‌های متفاوت رسانه‌های اجتماعی، شبکه‌های اجتماعی و سرویس‌های میکرو بلاگینگ<sup>۷</sup> به‌عنوان محبوب‌ترین و پر استفاده‌ترین سکوها شناخته می‌شوند. می‌توان شبکه‌های اجتماعی را سیستم‌های تحت وبی معرفی کرد که به کاربران خود امکان ایجاد نمایه<sup>۸</sup> شخصی و به اشتراک‌گذاری آن با دیگر کاربران در بستر شبکه را می‌دهند. منظور از سرویس‌های میکرو بلاگینگ نیز، سکوهایی است که به کاربران خود اجازه تولید و اشتراک‌گذاری محتوای خاص (وبلاگ‌نویسی) با طول و حجم کوتاه نسبت به وبلاگ‌نویسی سنتی را می‌دهند؛ این محتوا می‌تواند جملات کوتاه، تصویر و یا پیوندهای ویدئویی باشد که آن‌ها را پست یا گاه‌ها میکروپست می‌نامند. کاربران در این محیط می‌توانند با یکدیگر تعامل داشته باشند و به بیان احساسات<sup>۹</sup>، عواطف<sup>۱۰</sup> و افکار خود در گزارش‌های روزانه بپردازند (کاپلان و هانلین<sup>۱۱</sup>، ۲۰۱۰). تعداد بسیار زیاد و رو به رشد کاربران در انواع متفاوت رسانه‌های اجتماعی، تنوع زیاد و سادگی تولید محتوا در زمان بسیار کوتاه، این سکوها را به منابع بسیار بزرگ، در حال گسترش و ارزشمند داده‌های چندرسانه‌ای تبدیل نموده و همین مسئله سبب پیدایش شاخه کاوش و تحلیل رسانه‌های اجتماعی<sup>۱۲</sup> در بین موضوعات تحقیقاتی شده است. طبق آخرین آمار درج شده در پایگاه استاتیتستا<sup>۱۳</sup>، فیسبوک<sup>۱۴</sup>، توئیتر<sup>۱۵</sup> و اینستاگرام<sup>۱۶</sup>، به‌صورت ماهانه، به ترتیب ۲/۸ میلیارد، ۳۹۶ میلیون و ۱/۲ میلیارد کاربر فعال دارند. همچنین بر اساس اطلاعات هوت‌سوئیت<sup>۱۷</sup> در ژوئیه ۲۰۲۱، ۴/۴۸ میلیارد نفر یعنی تقریباً معادل ۵۸٪ جمعیت جهان، عضو شبکه‌های اجتماعی هستند. بعلاوه گفته می‌شود که کل کاربران منحصر به فرد در طول سال گذشته ۵۲۰ میلیون نفر افزایش یافته است که نشان دهنده رشد سالانه بیش از ۱۳٪ است<sup>۱۸</sup>. این آمار به داده عظیمی اشاره می‌کند که می‌توان با کاوش آن به اطلاعات ارزشمندی دست یافت؛ اطلاعاتی مانند الگوهای رفتاری کاربران که پیش‌تر در تحقیقات مرتبط با بازاریابی دیجیتال، بازاریابی هد، تجارت الکترونی، سفارشی‌سازی جستجو و سیستم‌های پیشنهاد گر قدرت خود را اثبات نموده است. پردازش و تحلیل این داده‌ها عموماً با هدف روندکاوی<sup>۱۹</sup>، تشخیص ساختار شبکه، تحلیل احساسات<sup>۲۰</sup>، نظرکاوی<sup>۲۱</sup>، مدیریت مخاطرات و مسائل امنیتی، موضوعات اجتماعی، توسعه کسب‌وکار، سیستم‌های پیشنهاد گر و تبلیغات و اهداف آموزشی صورت می‌گیرد. با این حال علی‌رغم پیشرفت‌های انجام شده و با توجه به پتانسیل داده‌های موجود در این زمینه، قابلیت‌های بسیاری کشف نشده باقی مانده است. بنابراین فارغ از دیدگاه تجاری و موضوعات مرتبط با شخصی‌سازی محتوا، سکوهایی شبکه‌های اجتماعی، منابع ارزشمند داده‌ای برای مطالعه و بررسی سلامت روان جامعه نیز هستند (وانکولپ و همکاران، ۲۰۱۷؛ سامانی و همکاران<sup>۲۲</sup>، ۲۰۱۸).

<sup>1</sup> <https://www.who.int/news-room/fact-sheets/detail/depression>

<sup>2</sup> Gao et al.

<sup>3</sup> Martínez-Castaño et al.

<sup>4</sup> Data Science

<sup>5</sup> Wongkoblap et al.

<sup>6</sup> Health care

<sup>7</sup> Microblogging services

<sup>8</sup> Profile

<sup>9</sup> Emotions

<sup>10</sup> Feelings

<sup>11</sup> Kaplan and Haenlein

<sup>12</sup> Social media analysis

<sup>13</sup> Statista

<sup>14</sup> Facebook

<sup>15</sup> Twitter

<sup>16</sup> Instagram

<sup>17</sup> Hootsuite

<sup>18</sup> <https://datareportal.com/reports/digital-2021-global-overview-report>

<sup>19</sup> Trend Mining

<sup>20</sup> Sentiment analysis

<sup>21</sup> Opinion mining

<sup>22</sup> Samani et al.



تحلیل داده‌های تولید شده در شبکه‌های اجتماعی (موسوم به داده‌های اجتماعی<sup>۱</sup>) منجر به کسب دانش کاربردی، افزایش کیفیت ارائه خدمات و تصمیم‌گیری آگاهانه‌تر خواهد شد. در نتیجه از جمله کاربردهای نهایی سیستم‌های توسعه داده شده بر پایه آن‌ها می‌توان به تحلیل وضعیت روانی، پیشگیری از وقوع حوادث، سنجش عملکرد شغلی و توانایی علمی افراد، بررسی تعاملات انسان و کامپیوتر و پاسخ‌های عاطفی به محتوای چندرسانه‌ای اشاره نمود. به همین دلیل شاهد رشد تدریجی استفاده از فناوری‌های مبتنی بر یادگیری ماشین در این زمینه هستیم (وانکولپ و همکاران، ۲۰۱۷). همان‌طور که پیش‌تر اشاره شد، موضوع اختلالات روان به‌عنوان بحران در حال وقوع از اهمیت بسیار بالایی برخوردار است. بنابراین نیاز به سازوکار و شیوه‌های نوینی وجود دارد تا بتوان این وضعیت را مدیریت کرد و در توسعه سیستم‌های خبره<sup>۲</sup> این زمینه، جوانب بیشتری را لحاظ نمود تا در نهایت با پیشرفت چنین سیستم‌هایی امکان ساخت پایگاه‌های دانش<sup>۳</sup> برای مسائل مشابه فراهم شود. بر اساس سوابق مسئله، پژوهش پیش‌رو یکی از اولین تلاش‌ها برای ترسیم نقشه راه در تحلیل داده اجتماعی با هدف شناسایی اختلال به صورت خودکار است که ضمن بررسی تازه‌ترین یافته‌ها، مکانیزمی جدید، کاربردی و خودکار برای جمع‌آوری و ارزیابی کاربران بر اساس اظهارات فرد ارائه می‌دهد. ما در مثالی کاربردی دو نوع ویژگی را در داده اجتماعی مورد بررسی قرار می‌دهیم و برای این کار از مدل‌های زبانی و فرهنگ لغت در پیاده‌سازی استفاده می‌کنیم. در نهایت با تجزیه و تحلیل ویژگی‌ها با استفاده از روش‌های طبقه‌بندی متفاوت و معیارهای ارزیابی استاندارد، عملکرد روش از جنبه‌های گوناگون مورد سنجش قرار می‌گیرد.

## ۲- ادبیات تحقیق

در این بخش مروری کوتاه بر تعاریف پایه، مبانی نظری و ادبیات موضوع خواهیم داشت تا با نگاهی دقیق‌تر پیشینه پژوهش‌های انجام شده در حوزه پیش‌بینی اختلال روانی بر مبنای شبکه‌های اجتماعی را مورد بررسی قرار دهیم.

### ۲-۱- سلامت روان الکترونیک

سلامت الکترونیک، خود یکی از شاخه‌های نسبتاً جدید در محاسبات فراگیر محسوب می‌شود که زمینه‌های کاربرد متفاوتی دارد؛ درمان از راه دور، تجویز و نسخ الکترونیک، پردازش داده‌های سلامت الکترونیک و کلان داده سلامت، سیستم‌های پشتیبان تصمیم بالینی، مدیریت دانش سلامت، مراقبت سلامت مجازی، سلامت سیار<sup>۴</sup> و انفورماتیک سلامت، از جمله شاخه‌های اصلی آن هستند. اما با دنبال نمودن تحقیقات این حوزه و رشد فناوری‌های شناختی، شاهد پیگیری مفهوم جدیدتری به نام سلامت روان الکترونیک (*E-mental health*) هستیم که مطالعات این حوزه اغلب به استفاده از فناوری اطلاعات و ارتباطات جهت مداخلات درمانی، با هدف حفظ سلامت روانی افراد متمرکز هستند. در واقع سلامت روان الکترونیک می‌تواند سبب افزایش دسترس‌پذیری خدمات بهداشت روان شود و همانند مشاوره رودررو در حفظ سلامت بیمار، جلوگیری از آسیب و ارتقا سلامت عمومی تأثیرگذار باشد. برخی از کاربردهای متنوع این شاخه تحقیقاتی عبارتند از مشاوره از راه دور، ابزارهای پوشیدنی و نظارت، تحلیل داده، مداخله از طریق رسانه‌های اجتماعی، واقعیت مجازی، ربات‌های سلامت، مداخله از طریق بازی و سرگرمی و نرم‌افزارهای کاربردی. اگرچه نمی‌توان مرز شفافیتی بین برخی کاربردها در نظر گرفت اما از میان موارد فهرست شده، عمده مباحث این تحقیق بر تحلیل داده و مداخله از طریق رسانه‌های اجتماعی متمرکز است.

روند کلی به‌کارگیری مدل‌های یادگیری ماشین در این زمینه، به ترتیب شامل طراحی سازوکار تحلیل، ارائه پرسشنامه به گروه‌های از پیش تعیین شده، درخواست دسترسی به داده‌ها و جمع‌آوری داده، آموزش مدل بر اساس نمونه‌های مستخرج از پرسشنامه و سنجش دقت تخمین بر اساس نمونه‌های آزمون و مشاهده نشده است. این در شرایطی است که فقدان مجموعه داده، مانعی عظیم در توسعه تحقیقات کاربردی سلامت روان از لحاظ تشخیص‌های قابل اطمینان و درمان مؤثر بسیاری از اختلالات است و حل این مسئله می‌تواند کلید حل انفورماتیک بحران<sup>۵</sup> (پارک و همکاران<sup>۶</sup>، ۲۰۱۹)، تشخیص فوری، مداخله و درمان مؤثر باشد. ابزار اصلی مطالعات سلامت روان پرسشنامه‌ها هستند و عمده مطالعاتی که در بررسی گنجانده شده با استفاده از پرسشنامه‌ها و نظرسنجی‌ها اقدام به شناسایی ویژگی‌های روانی کاربر نموده‌اند؛ اما علاوه بر هزینه، تعداد شرکت‌کنندگان بسته به پرسشنامه‌های تکمیل شده و مجوزهای تخصیص داده شده از

<sup>1</sup> Social data

<sup>2</sup> Expert systems

<sup>3</sup> Knowledge bases

<sup>4</sup> Mobile health

<sup>۵</sup> منظور از انفورماتیک بحران یا Crisis informatics، استفاده از فناوری

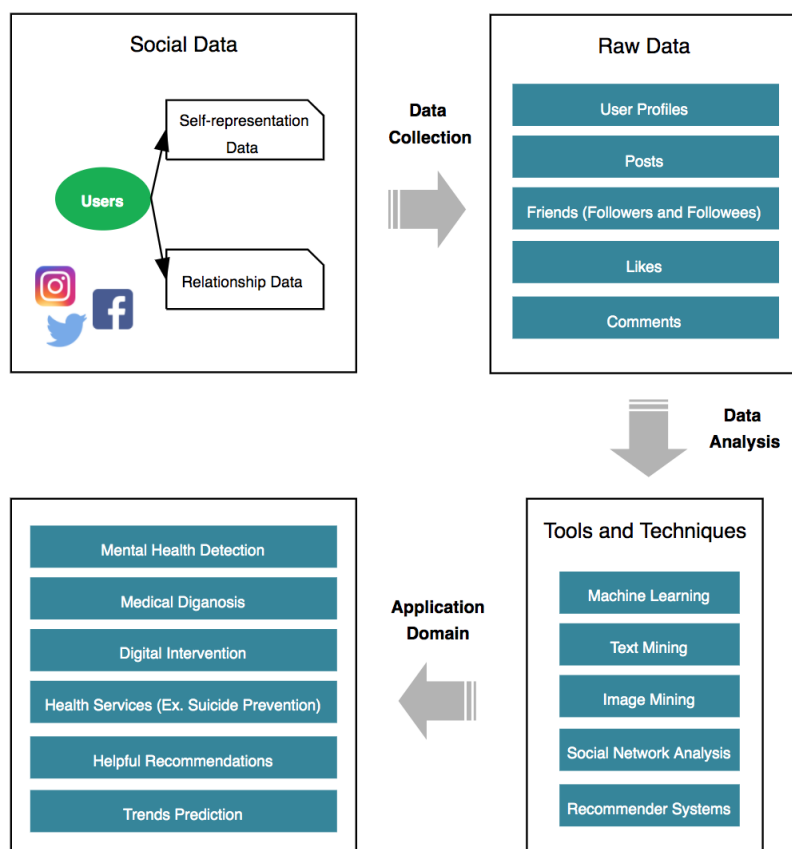
اطلاعات برای آماده‌سازی، کاهش اثرات و واکنش مناسب نسبت به بلایا و شرایط اضطراری است.

<sup>6</sup> Park et al.



سوی کاربران بسیار محدود است (کوپر اسمیت و همکاران<sup>۱</sup>، ۲۰۱۴؛ ریزولا و همکاران<sup>۲</sup>، ۲۰۲۰). همچنین بر اساس تحقیقات گذشته، استفاده از پرسشنامه در روش تحقیق معمولاً سبب تأخیر طولانی بین فاز جمع‌آوری داده‌ها و انتشار یافته‌ها یا مداخلات فوری خواهد شد (دی چاندهاری<sup>۳</sup>، ۲۰۱۳). بعلاوه افراد مبتلا به اختلال معمولاً تمایل چندانی به همکاری با روش‌های تحقیقاتی تعاملی ندارند.

عمده کارهای بررسی شده بر روی پست‌های کاربر متمرکز هستند، در حالی که انواع متفاوتی از داده‌های اجتماعی در دسترس قرار دارند و می‌توانند با هدف بررسی نشانه‌ها تحلیل شوند. بنابراین با وجود نوپا بودن این حوزه تحقیقاتی، جزئیات زیادی از داده‌های اجتماعی در حوزه اختلالات روان کشف نشده باقی مانده است. ابعاد متفاوت این مسائل در ادامه به صورت کامل تشریح خواهد شد و در اینجا نمای سطح بالایی تحلیل داده‌های اجتماعی از منظر سلامت روان، در شکل ۱ ترسیم شده است.



شکل ۱- چارچوب مفهومی تحلیل سلامت روان بر اساس داده‌های اجتماعی.

Figure 1- Conceptual framework for mental health analysis based on social data.

بر این اساس، صرف نظر از جزئیات مربوط به هر ماژول، پس از جمع‌آوری داده‌های هدف، مراحل پیش‌پردازش انجام شده و با پیاده‌سازی روش پیشنهادی، متناسب با رویکرد تحلیل انتخاب شده، نتایج مورد ارزیابی قرار می‌گیرند. در نهایت در صورت کسب معیارهای لازم، می‌توان به ارائه مکانیزم‌هایی جهت مداخلات دیجیتال در بستر شبکه اجتماعی اندیشید. این مداخلات می‌توانند شامل ترویج دسترسی به خدمات سلامت، مداخلات فوری، پیشنهاد پیوندهای حاوی اطلاعات سلامت و یا رفتار درمانی شناختی (نشانه‌گیری احساسات ناکارآمد، رفتارها و مضامین شناختی ناسازگارانه از طریق شماری از روش‌های سیستماتیک، صریح و هدف‌مدار) باشند. همچنین این مداخلات ممکن است از طریق تبلیغات و یا کمک بلادرنگ (مانند آنچه فیسبوک به‌عنوان یک ابزار جلوگیری از خودکشی در نظر گرفته است (کالیسون بارچ و همکاران<sup>۴</sup>، ۲۰۱۷)) به کاربر ارائه شوند.

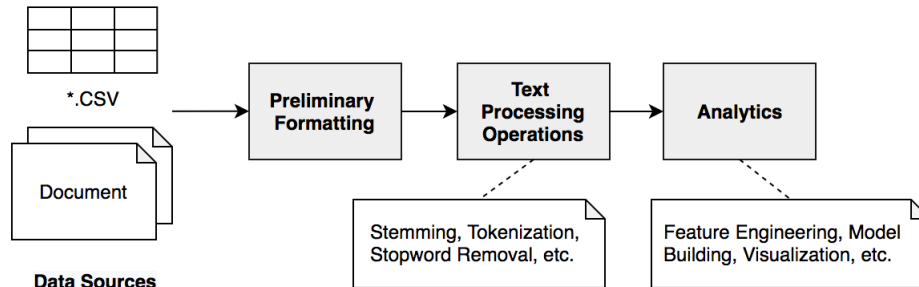
<sup>1</sup> Coppersmith et al.

<sup>2</sup> Rissola et al.

<sup>3</sup> De Choudhury

<sup>4</sup> Callison-Burch et al.

رایج‌ترین نوع از انواع داده‌ای، متن است که در حوزه‌های متفاوت مورد توجه قرار می‌گیرد. به صورت عمومی می‌توان فرآیند متن‌کاوی را در قالب یک معماری سطح بالا، به شکل ۲ ترسیم نمود. این فرآیند شامل سه مرحله آماده‌سازی متن (ورودی)، عملیات پردازش متن مانند عملیات پایه ریشه‌یابی<sup>۱</sup>، توکن‌سازی<sup>۲</sup> و حذف کلمات اضافه<sup>۳</sup> و تجزیه و تحلیل خروجی مانند انتخاب ویژگی، توسعه مدل و بصری‌سازی است. البته فرآیند متن‌کاوی در هر کاربرد با چالش‌هایی نیز مواجه است، که تنوع نمایش اسناد، ابعاد بالا در فضای ویژگی<sup>۴</sup> و چگونگی انتخاب ویژگی، استخراج کلمه/عبارت، چگونگی کاهش ابعاد و ابهامات زبان طبیعی از جمله آن‌ها هستند.



شکل ۲- نمایی از فرآیند متن‌کاوی.

Figure 2- The text mining process.

همان‌طور که در بخش قبل اشاره شد، داده‌های موجود در شبکه‌های اجتماعی (داده اجتماعی)، مواد اصلی در فرآیند پردازش و تحلیل هستند که انواع متفاوتی دارند. داده‌هایی که کاربر جهت استفاده از خدمات در اختیار سکو قرار می‌دهد (مانند اطلاعات هویتی)، داده‌هایی که کاربر آن‌ها را روی نمایه کاربری و صفحه خود قرار می‌دهد (مانند تصاویر و پست‌ها)، پیام‌های ردوبدل شده بین کاربران، و داده‌های رفتاری<sup>۵</sup> که شامل جمع‌آوری انواع فعالیت‌های انجام شده توسط کاربر است؛ مانند تصاویری که کاربر آن‌ها را پسندیده و یا خبرها و موضوعاتی که به‌طور معمول دنبال می‌کند. بنابراین بدیهی است که با استفاده از علم داده و تحلیل داده‌های تولید شده توسط کاربر، می‌توان اطلاعات نامحسوس و پنهان را در لایه‌ها و کاربردهای متفاوت استخراج نمود.

شایان ذکر است که از منظر سیاست‌های حریم خصوصی هر سکو، دسترسی به این داده‌ها معمولاً با مجوز سکو و کاربر صورت می‌گیرد؛ بنابراین اولین گام در فرآیند تحلیل، دستیابی به داده‌های هدف است. موضوع بعدی پیچیدگی و حجم بسیار بالای داده‌های تولید شده است که اهمیت مرحله پیش‌پردازش را مضاعف می‌کند.

### ۳- پیش‌بینی اختلال روان در شبکه‌های اجتماعی

یکی از این زمینه‌های تحقیقاتی داغ کاوش شبکه‌های اجتماعی، سلامت الکترونیک و سیستم‌های مراقبت سلامت است. بررسی و پیش‌بینی بیماری، اثربخشی درمان، پایش، پیشگیری و مدیریت مراقبت سلامت از موضوعاتی هستند توجه محققان این حوزه را به خود جلب نموده است. الگوهای رفتاری در شبکه‌های اجتماعی از طریق ابزارهای متن‌کاوی قابل شناسایی هستند؛ برای مثال برخی پژوهش‌ها، تحلیل و تشخیص نشانه‌های اختلال روانی را از طریق به‌روزرسانی وضعیت در شبکه‌های اجتماعی مورد مطالعه قرار دادند (مورنو و همکاران<sup>۶</sup>، ۲۰۱۱). می‌توان روش‌های ارائه شده را از دیدگاه روش جمع‌آوری داده و سازوکار تحلیل، به گروه‌های متفاوتی تقسیم نمود. در ادامه مطالعاتی که تنها بر تحلیل انسانی متکی بوده و یا شرایط تحقیق را برآورده نمی‌کردند، از بررسی خارج شده و با رویکردی مدون، بر جزئیات مقالات منتخب، شامل چگونگی جمع‌آوری داده‌ها، پیش‌پردازش داده‌ها، استخراج و انتخاب ویژگی، ساخت مدل پیش‌بینی و تأیید مدل ۷، تمرکز می‌شود.

<sup>1</sup> Stemming

<sup>2</sup> Tokenization

<sup>3</sup> Stop-word removal

<sup>4</sup> High dimensional feature space

<sup>5</sup> Behavioral data

<sup>6</sup> Moreno et al.

<sup>7</sup> Model verification





می‌توان مطالعات صورت گرفته در حوزه تشخیص اختلالات روان را از دیدگاه روش جمع‌آوری داده به دو گروه کلی تقسیم نمود: الف) جمع‌آوری داده به‌طور مستقیم و با رضایت کاربر، از طریق نظرسنجی و پرسشنامه، به کمک ابزارهای جمع‌آوری (مانند نرم‌افزارهای کاربردی موجود در فیسبوک)، و ب) استخراج داده از پست‌های عمومی کاربران، به وسیله رابط برنامه‌نویسی کاربردی<sup>۱</sup> یا API سکو.

رویکرد اول بسته به هدف مطالعه و سکوی مورد نظر می‌تواند متفاوت باشد. ارسال دعوت‌نامه و انتشار اطلاعات پروژه در وبسایت‌های مربوطه و جمع‌سپاری<sup>۲</sup> (مانند *OurDataHelps*<sup>۳</sup>) را می‌توان به‌عنوان مثالی از آن در نظر گرفت؛ در این روش به‌طور معمول در بخشی از پرسشنامه از شرکت‌کننده خواسته می‌شود تا به‌طور آگاهانه، رضایت خود را درباره جمع‌آوری و استفاده از داده‌های شخصی در شبکه اجتماعی اعلام کند (کوپر اسمیت و همکاران، ۲۰۱۸؛ شوارتز و همکاران<sup>۴</sup>، ۲۰۱۶؛ بریسویت و همکاران<sup>۵</sup>، ۲۰۱۶). به‌منظور سنجش میزان رضایت از زندگی و سطح افسردگی، طیف نسبتاً وسیعی از پرسشنامه‌ها طراحی شده است که برخی از شناخته‌شده‌ترین آن‌ها عبارتند از (وانکولپ و همکاران، ۲۰۱۷): پرسشنامه مرکز مطالعات اپیدمیولوژیک سطح افسردگی<sup>۶</sup>، پرسشنامه سلامت بیمار<sup>۷</sup>، افسردگی یک<sup>۸</sup> و پرسشنامه تجدید نظر شده اصالت شخصیت<sup>۹</sup> (پنج عامل بزرگ شخصیت<sup>۱۰</sup> به همراه شش زیر شاخه<sup>۱۱</sup> برای هر عامل). به این ترتیب در نهایت در تحقیقاتی که از پرسشنامه استفاده می‌کنند، با ساخت مدلی بر مبنای داده‌های دارای برجسب، روند ارزیابی طرح پیشنهادی و تخمین دقت دنبال می‌شود. در این رویکرد، ابتدا از نتایج حاصل از پرسشنامه به‌عنوان مجموعه داده‌های آموزشی<sup>۱۲</sup> برای ساخت مدل استفاده می‌شود و در گام بعد، دقت مدل با استفاده از داده‌های مشاهده نشده (داده‌های فاقد برجسب یا مجموعه آزمون<sup>۱۳</sup>) و مقایسه نتایج مدل با واقعیت، اندازه‌گیری می‌شود.

با توجه به اینکه واسط‌های برنامه‌نویسی کاربردی در سکوهای اجتماعی به توسعه‌دهندگان اجازه دستیابی به داده‌های عمومی را می‌دهند، در رویکرد دوم از کلمات یا عبارات با قاعده<sup>۱۴</sup> با هدف جستجوی پست‌های مرتبط استفاده می‌شود. برای مثال، برخی تحقیقات جهت بازیابی پست‌های مرتبط با ایده خودکشی یا افکار آسیب به خود از کلمات و عباراتی مانند “suicide”، “self-harm”، “kill myself” و “want to die” و برخی دیگر برای بازیابی انواع متفاوت اختلال روانی از الگوی “I was diagnosed with [disorder]” (کوپر اسمیت و همکاران، ۲۰۱۴؛ لوسادا و کرسطانی<sup>۱۵</sup>، ۲۰۱۶؛ ریزولا و همکاران، ۲۰۲۰) استفاده نموده‌اند، که رویکرد دوم به روش تشخیص متکی بر گزارش فرد<sup>۱۶</sup> مشهور است. به علت نبود استانداردی مشخص جهت جمع‌آوری داده‌ها در شبکه‌های اجتماعی، هر منبع داده نیاز به یک مکانیزم ضبط سفارشی دارد. از میان منابع داده‌ای مورد بحث، فیسبوک یکی از محبوب‌ترین سکوها در بین کاربران است؛ با این حال، تنها چند پژوهش با هدف پیش‌بینی اختلالات روانی مجموعه داده‌های آن را مورد مطالعه قرار دادند. یکی از دلایل این موضوع این است که کاربران فیسبوک به‌طور پیش‌فرض نمایه خود را در دسترس عموم قرار نمی‌دهند و گرفتن اطلاعات در این سکو، نیاز به رضایت مستقیم کاربر دارد. آزمایش‌های مبتنی بر فیسبوک با ایجاد ابزارهای سفارشی یا برنامه‌های تحت وبی که به رابط برنامه‌نویسی کاربردی فیسبوک متصل می‌شوند، مجموعه داده‌های کاربران را جمع‌آوری می‌کنند. گروهی دیگر از مطالعات از API<sup>۱۷</sup> توئیتر جهت شناسایی نشانه‌های اختلال روانی استفاده می‌کنند. توئیتر منبع محبوب داده‌های اجتماعی در مقالات بررسی شده است که دو روش را برای دسترسی به داده‌ها فراهم می‌کند: روش گذشته‌نگر<sup>۱۸</sup> (با استفاده از API<sup>۱۸</sup>های جستجو<sup>۱۸</sup>) و روش آینده‌نگر<sup>۱۹</sup> (از طریق API<sup>۱۹</sup>های جریان<sup>۲۰</sup>). دسترسی گذشته‌نگر، امکان جستجو عبارات با قاعده روی مجموعه‌ای کامل از توئیتهای تاریخی را میسر می‌کند، درحالی‌که دسترسی آینده‌نگر امکان ضبط توئیتهای آینده را مطابق با جستجو فراهم می‌کند. با این حال، جستجوی آینده‌نگر دسترسی به تنها ۱٪ توئیتهای عمومی بلادرنگ<sup>۲۱</sup> را بر اساس فیلترهای مشخص فراهم می‌کند. البته توئیتر یک منبع جایگزین به نام *Firehose* نیز ارائه می‌دهد که تنها از طریق

<sup>1</sup> Application programming interface (API)

<sup>2</sup> Crowdsourcing

<sup>3</sup> <https://ourdatahelps.org>

<sup>4</sup> Schwartz et al.

<sup>5</sup> Braithwaite et al.

<sup>6</sup> Center for epidemiologic studies depression scale

<sup>7</sup> Patient health questionnaire-9

<sup>8</sup> Beck depression inventory

<sup>9</sup> Revised NEO personality inventory

<sup>10</sup> Big five personality traits

<sup>11</sup> Facet

<sup>12</sup> Train set

<sup>13</sup> Test set

<sup>14</sup> Regular expression (regex)

<sup>15</sup> Losada and Crestani

<sup>16</sup> Self-reported diagnosis

<sup>17</sup> Retrospective

<sup>18</sup> Search APIs

<sup>19</sup> Prospective

<sup>20</sup> Streaming APIs

<sup>21</sup> Real-time

خرید اشتراک قابل استفاده است و جستجو روی تمام توئیتهای عمومی را ممکن می‌سازد و در برخی مطالعات خاص استفاده شده است.<sup>۱</sup> دسترسی به داده‌ها در اینستاگرام و سینا ویبو<sup>۲</sup> نیز با استفاده از APIها انجام می‌شود.

تفاوت‌های قابل توجهی بین مطالعات انجام شده روی فیسبوک و مطالعات روی سیستم‌های میکرو بلاگینگ مانند توئیتر یا سینا ویبو وجود دارد؛ فیسبوک به توسعه‌دهندگان اجازه نمی‌دهد که به تعاملات و ارتباطات دوستی بین کاربران دسترسی پیدا کنند. کاربران باید رضایت خود را به صورت صریح ارائه دهند تا برنامه کاربردی قادر به جمع‌آوری داده‌ها باشد. در نتیجه، تحقیقی مشاهده نشد که از تجزیه و تحلیل شبکه‌های اجتماعی (با استفاده از خزنده<sup>۳</sup>) برای اندازه‌گیری و پیش‌بینی مشکلات سلامت روان روی داده‌های فیسبوک استفاده کرده باشد (وانکولپ و همکاران، ۲۰۱۷). این در حالی است که سایت‌های میکرو بلاگینگ، دسترسی به چنین اطلاعاتی را فراهم می‌کنند. این سایت‌ها APIs را ارائه می‌دهند که به توسعه‌دهندگان اجازه می‌دهد اطلاعات مربوط به دنبال‌کنندگان<sup>۴</sup> و دنبال‌شوندگان<sup>۵</sup> را به دست آورند و تعاملات کاربران را نیز به صورت گراف‌های شبکه اجتماعی ایجاد کنند. در حوزه جمع‌آوری داده‌ها از کاربران، بین دریافت داده‌ها از طریق رضایت شرکت‌کنندگان و استفاده از عبارات باقاعده جهت جستجوی پست‌های مرتبط نیز تفاوت‌هایی وجود دارد. گزینه اول می‌تواند منجر به ارائه جزئیات اختلال روانی از سوی شرکت‌کنندگان شود و روش دوم، زمان و هزینه شناسایی کاربران مبتلا به بیماری را کاهش می‌دهد. بعلاوه امکان بهره‌گیری از روش دوم در شرایط فقدان داده‌های بالینی، کمک بلادرنگ، یا زمانی که کاربران تمایلی به مشارکت مستقیم نداشته باشند، به ویژه در کاربردهای دنیای واقعی، می‌تواند مثر باشد.

اضافه می‌کنیم که روش سومی نیز برای به دست آوردن داده‌ها مورد استفاده قرار می‌گیرد و آن استفاده از داده‌های ارائه شده توسط پروژه *myPersonality* است<sup>۶</sup> که داده‌های شبکه اجتماعی و نتایج آزمون‌های روان‌سنجی را برای تحقیقات دانشگاهی فراهم می‌کند. *myPersonality* در حقیقت یک نرم افزار کاربردی فیسبوک بود که به کاربران اجازه می‌داد از طریق تکمیل پرسشنامه شخصیت، در تحقیق روانشناختی مشارکت کنند. مجموعه داده‌های این پروژه شامل امتیازهای کاربر در پنج عامل بزرگ شخصیت است؛ مدل پنج عامل بزرگ شخصیت که با نام‌های *FFM*<sup>۷</sup> و *OCEAN* یا *CANOE* نیز شناخته می‌شود یک آزمون تجربی برای اندازه‌گیری متغیرهای شخصیت است که بر اساس آن شخصیت از پنج بعد اصلی روان‌رنجوری<sup>۸</sup>، برون‌گرایی<sup>۹</sup>، سازگاری (موافق بودن)<sup>۱۰</sup>، استقبال از تجربه<sup>۱۱</sup> و وظیفه‌شناسی (با وجدان بودن)<sup>۱۲</sup> تشکیل شده است. این پروژه در سال ۲۰۰۷ توسط دیوید استیلول<sup>۱۳</sup> (مدرس دانشگاه کمبریج) کلید خورد و در سال ۲۰۱۲ به دلایلی انتشار داده را متوقف کرد. همچنین برخی پژوهش‌ها از داده‌های تأیید و منتشر شده توسط کمیته علمی کارگاه‌های تخصصی جهت تحلیل استفاده می‌کنند؛ به این صورت که انواع نمرات آزمون‌های روان‌سنجی و داده‌های اجتماعی کاربران برای اهداف دانشگاهی فراهم شده و (تا زمان نگارش این تحقیق) برای پژوهشگران حوزه تحلیل متن قابل استفاده هستند. کارگاه زبان‌شناسی محاسباتی و روانشناسی بالینی<sup>۱۴</sup> (*CLPsych*) (لوسادا و کرستانی<sup>۱۵</sup>، ۲۰۱۶) و پروژه *eRisk*<sup>۱۶</sup> (لوسادا و همکاران<sup>۱۷</sup>، ۲۰۲۰) از جمله این موارد هستند. با در نظر گرفتن این مسئله که مجموعه داده‌های از پیش تعریف شده، اطلاعات محدودی را جهت تحلیل ارائه می‌دهند، در ادامه عمدتاً تحقیقاتی را مورد بررسی قرار می‌دهیم که از رویکرد عبارات با قاعده برای جمع‌آوری داده استفاده می‌کنند.

در تمام مطالعات منتخب، پس از استخراج داده از طریق *API* و قبل از اعمال الگوریتم‌های یادگیری ماشین روی داده‌ها، چند گام استاندارد برای ارزیابی پیش از تحلیل باید برداشته شود. نخست، داده‌ها پاکسازی شده و پیش‌پردازش می‌شوند تا به فرم مورد نیاز الگوریتم‌های تحلیلی تبدیل شوند. سپس ویژگی‌های کلیدی مرتبط با حوزه تحقیق برای ساخت مدل فراهم می‌شوند. به‌طورکلی، این مرحله شامل استخراج و انتخاب ویژگی، تولید مجموعه‌ای از ویژگی‌ها برای استفاده در مرحله یادگیری و اعتبارسنجی مدل‌های پیش‌بینی است. بنابراین توضیحات بخش بعد را با مبحث پیش‌پردازش داده‌ها ادامه می‌دهیم.

<sup>1</sup> <https://developer.twitter.com/en>

<sup>2</sup> Sina weibo

<sup>3</sup> Crawler

<sup>4</sup> Followers

<sup>5</sup> Followees

<sup>6</sup> <http://mypersonality.org>

<sup>7</sup> Five factor model

<sup>8</sup> Neuroticism

<sup>9</sup> Extraversion

<sup>10</sup> Agreeableness

<sup>11</sup> Openness to experience

<sup>12</sup> Conscientiousness

<sup>13</sup> David Stillwell

<sup>14</sup> <https://clpsych.org>

<sup>15</sup> Losada and Crestani

<sup>16</sup> <https://erisk.irlab.org>

<sup>17</sup> Losada et al.







از پیش‌پردازش و آماده‌سازی داده‌ها معمولاً به‌عنوان مهم‌ترین و زمان‌برترین مرحله در پروژه‌های داده‌کاوی یاد می‌شود. چرا که داده‌های خام اغلب ناقص، مغشوش<sup>۱</sup> و ناسازگار هستند. به همین جهت مراحل پاکسازی و حذف نمونه‌های نامناسب، یکپارچه‌سازی، تبدیل و کاهش داده در پیش‌پردازش در نظر گرفته می‌شوند. برای مثال در روش جمع‌آوری داده با استفاده از کلمات و عبارات کلیدی مرتبط با خودکشی، در صورتی که پست بازایی شده نفی ایده خودکشی، بحث در مورد خودکشی سایر افراد، خبر و یا گزارشی در این‌باره باشد، به‌عنوان پست غیر مرتبط در نظر گرفته شده و از مجموعه داده حذف می‌شود. به همین ترتیب، در روش تشخیص مبتنی بر اظهارات فرد، با بررسی انسانی، تنها پست‌هایی که حاوی بیانات فرضی<sup>۲</sup>، نفی و یا نقل قول<sup>۳</sup> نباشند به‌عنوان نمونه مثبت در نظر گرفته می‌شوند. همچنین اطلاعات و پرسشنامه‌های شرکت‌کنندگان ممکن است حاوی داده‌های بی‌فایده و جزئیات ناقص باشند که به‌منظور بهبود دقت پیش‌بینی و نتایج طبقه‌بندی حذف می‌شوند. در برخی مطالعات، اطلاعات مربوط به شرکت‌کنندگانی که مدت زمان کوتاه یا بلندی به تکمیل پرسشنامه اختصاص داده بودند نیز غیرعادی تلقی شده و مجموعه حذف شدند (تسوگاوا و همکاران<sup>۴</sup>، ۲۰۱۵؛ دی چاندھاری و همکاران<sup>۵</sup>، ۲۰۱۳). همین‌طور اگر شرکت‌کننده‌ای کمتر از حد آستانه تعریف شده داده منتشر نموده بود در مرحله ارزیابی در نظر گرفته نمی‌شد (سراویا و همکاران<sup>۶</sup>، ۲۰۱۶؛ لیو و همکاران<sup>۷</sup>، ۲۰۱۵؛ بولن و همکاران<sup>۸</sup>، ۲۰۱۱). در برخی تحقیقات نیز در صورتی که بین اطلاعات وارد شده شرکت‌کنندگان در دو پرسشنامه متفاوت همبستگی ضعیفی استنتاج می‌شد، داده‌های مربوط به آن افراد در مجموعه داده نهایی در نظر گرفته نمی‌شدند (تسوگاوا و همکاران، ۲۰۱۵).

بخش دیگری از پاکسازی بر اساس زبان غالب نوشتار انجام می‌شود؛ به این صورت که متن واجد شرایط باید تا ۷۰٪ انگلیسی تشخیص داده شود. این کار باعث می‌شود اطمینان حاصل کنیم که ابزارهای موجود برای تحلیل پست‌ها مناسب هستند. در اکثر مطالعات هر پست با حذف کلمات اضافه و داده‌های کم اهمیت (مانند توییت‌های باز نشر شده<sup>۹</sup>، هشتگ‌ها<sup>۱۰</sup> و نشانی‌های اینترنتی<sup>۱۱</sup>)، تبدیل کارکترهای بزرگ به کوچک<sup>۱۲</sup> و بخش‌بندی<sup>۱۳</sup> جملات پیش‌پردازش می‌شود (دو و همکاران<sup>۱۴</sup>، ۲۰۱۸؛ ما و همکاران<sup>۱۵</sup>، ۲۰۱۷؛ چن و همکاران<sup>۱۶</sup>، ۲۰۱۸). شکلک‌ها<sup>۱۷</sup> به فرم قابل درک برای ماشین مانند کد اسکی<sup>۱۸</sup> تبدیل می‌شوند و همچنین مرحله‌ای برای ناشناس‌سازی<sup>۱۹</sup> حساب‌های کاربری در نظر گرفته می‌شود.

### ۳-۳- استخراج و انتخاب ویژگی

تکنیک‌های بسیاری برای استخراج ویژگی‌های مناسب جهت پیش‌بینی مشکلات سلامت روان در کاربران شبکه‌های اجتماعی مورد استفاده قرار می‌گیرند. مطالعات متعددی با بررسی محتویات متنی<sup>۲۰</sup> شبکه‌های اجتماعی تلاش کرده‌اند به این پرسش پاسخ دهند که چه نشانه‌هایی بیانگر اختلالات روانی هستند. برخی تحقیقات نیز از روش‌های جایگزین مانند تحلیل تصویر<sup>۲۱</sup> و تعاملات اجتماعی<sup>۲۲</sup> استفاده نمودند. متن‌کاوی، تحلیل احساسات و یا عقیده‌کاوی<sup>۲۳</sup> ابزاری محبوب برای درک عبارت احساسی است که برای طبقه‌بندی قطبیت<sup>۲۴</sup> متن مورد نظر به دسته‌های مثبت، منفی یا خنثی<sup>۲۵</sup> به‌کار گرفته می‌شود (سان و همکاران<sup>۲۶</sup>، ۲۰۱۷). در تجزیه و تحلیل احساسات جنبه گرا، متنی غیرساخت یافته به‌عنوان ورودی دریافت شده و پس از تعیین موجودیت‌ها و ویژگی‌ها، قطبیت هر ویژگی برای هر موجودیت به‌عنوان خروجی ارائه می‌شود.

<sup>1</sup> Noisy  
<sup>2</sup> Hypotheticals statement  
<sup>3</sup> Quotes  
<sup>4</sup> Tsugawa et al.  
<sup>5</sup> De Choudhury et al.  
<sup>6</sup> Saravia et al.  
<sup>7</sup> Liu et al.  
<sup>8</sup> Bollen et al.  
<sup>9</sup> Retweets  
<sup>10</sup> Hashtag  
<sup>11</sup> URLs  
<sup>12</sup> Lowercasing  
<sup>13</sup> Segmenting

<sup>14</sup> Du et al.  
<sup>15</sup> Ma et al.  
<sup>16</sup> Chen et al.  
<sup>17</sup> Emoticons  
<sup>18</sup> ASCII codes  
<sup>19</sup> Anonymization  
<sup>20</sup> Textual contents  
<sup>21</sup> Image analysis  
<sup>22</sup> Social interactions  
<sup>23</sup> Opinion mining  
<sup>24</sup> Polarity  
<sup>25</sup> Neutral  
<sup>26</sup> Sun et al.



رایج ترین ابزار برای تجزیه و تحلیل متن در تحقیقات روانشناختی لوک (LIWC<sup>1</sup>) است. لوک یک نرم افزار کاربردی تحلیل متن شناخته شده است که اغلب برای به دست آوردن الگوهای زبانی در مطالعات مرتبط استفاده شده است (ریزولا و همکاران، ۲۰۲۰؛ چن و همکاران، ۲۰۱۸؛ لایوز و همکاران<sup>۲</sup>، ۲۰۱۷؛ چن و همکاران، ۲۰۱۸). لوک به صورت دستی توسط روانشناسان ساخته شده و مجهز به مجموعه ای از لغت نامه هایی است که دسته های گوناگون و معنادار روانشناسی را پوشش می دهند؛ به طوری که می توان از آن برای استخراج سیگنال های بالقوه از محتوای متنی (مانند ضمائم شخصی و احساسات مثبت یا منفی) استفاده نمود. لوک بسیاری از ویژگی های طبقه بندی شده مانند نقش کلمات در جمله<sup>۳</sup> و کلمات احساسی را از داده های متنی استخراج می کند؛ البته لازم به ذکر است که لوک یک نرم افزار اختصاصی است و کاربران مجبور به خرید مجوز برای استفاده از آن هستند. نحوه عملکرد لوک به این شکل است که کاربران فایل یا فایل های مورد نظر خود را به عنوان ورودی به نرم افزار می دهند و نرم افزار ویژگی های مرتبط و مقادیر هر ویژگی را به عنوان خروجی برمی گرداند. بنابراین باید در نظر داشت که پایگاه داده ویژگی ها در آن به راحتی قابل تغییر نیست. لوک توسط پژوهشگران حوزه سلامت روان و شناخت جهت شمارش میزان رخداد کلمات بیانگر احساسات و سبک تفکر اجتماعی توسعه یافته که بر مبنای ماژول تحلیل متن (نوشته شده به زبان جاوا) و مجموعه ای از دیکشنری های تعریف شده عمل می کند. در لوک ماژول تحلیل متن در عمل مقایسه ای، درصد کلمات مطابق با دیکشنری را مشخص می کند؛ به این ترتیب مشخص می شود که کدام کلمه به کدام دسته روانشناختی تعریف شده مرتبط است.

لوک ۲۰۱۵ دارای سه دیکشنری داخلی است: دیکشنری لوک ۲۰۱۵، ۲۰۰۷ و ۲۰۰۱. دیکشنری لوک ۲۰۱۵ شامل حدود ۶۴۰۰ کلمه، ریشه کلمات و شکلک های منتخب است؛ به طوری که برای هر کلمه در دیکشنری یک یا چند دسته تعریف شده است. برای مثال کلمه "Cried" جزئی از پنج دسته غم و اندوه<sup>۴</sup>، احساس منفی<sup>۵</sup>، تأثیر کلی<sup>۶</sup>، فعل<sup>۷</sup> و تمرکز بر گذشته<sup>۸</sup> است. از این رو، اگر کلمه "Cried" در متن هدف مشاهده شود امتیاز هر یک از این پنج دسته افزایش می یابد. همان طور که از مثال قابل تصور است بسیاری از دسته های لوک ۲۰۱۵ به صورت سلسله مراتبی در نظر گرفته شده اند. به این معنی که تمام کلمات مرتبط با دسته غم و اندوه، به عنوان کلمات مرتبط با دسته های احساس منفی و تأثیر کلی نیز تعبیر می شوند<sup>۹</sup>.

برای رفع موانع در استفاده از لوک، ابزارهای جایگزینی جهت استخراج ویژگی ها معرفی شده اند که البته نسبتاً محدود بوده و تنها قادر به استخراج برخی ویژگی ها هستند. WordNet یک لغت نامه بزرگ انگلیسی است که می تواند برای استخراج نقش کلمات در متن و یافتن معنای<sup>۱۰</sup> کلمه استفاده شود<sup>۱۱</sup>. OpinionFinder (ویلسون و همکاران<sup>۱۲</sup>، ۲۰۰۵) و SentiStrength (تلوال و همکاران<sup>۱۳</sup>، ۲۰۱۰) نیز از ابزارهای محبوب تجزیه و تحلیل احساسات هستند که غالباً در مقالات تحقیقاتی منتخب برای کمی سازی احساسات در عبارات متنی مورد استفاده قرار گرفته اند (بولن و همکاران<sup>۱۴</sup>، ۲۰۱۱؛ دوراهیم و کاسکن<sup>۱۵</sup>، ۲۰۱۵). OpinionFinder، ذهنیت، عینیت و تحلیل احساسات را ارائه می کند. OpinionFinder در واقع یک سیستم پردازش اسناد است که توسط محققان دانشگاه پیتسبورگ، دانشگاه کرنل و دانشگاه یوتا ساخته شد و به طور خودکار جملات ذهنی<sup>۱۶</sup> و همچنین جنبه های مختلف ذهنیت در جملات (شامل عواملی<sup>۱۷</sup> که منبع نظر هستند، عبارات مستقیم ذهنی<sup>۱۸</sup>، رویدادهای سخنرانی<sup>۱۹</sup> و عبارات احساسی را شناسایی می کند (ویلسون و همکاران، ۲۰۰۵). Mallet یک ابزار پردازش زبان طبیعی مفید طبقه بندی<sup>۲۰</sup> و یا خوشه بندی<sup>۲۱</sup> اسناد، ایجاد موضوعات و برچسب گذاری توالی<sup>۲۲</sup> است<sup>۲۳</sup>. SentiStrength نیز قطبیت بین کلمات مثبت و منفی و سطوح قدرت کلمات مثبت و منفی را در یک پیام متنی ارزیابی می کند<sup>۲۴</sup>.

<sup>1</sup> Linguistic Inquiry and Word Count (LIWC)

<sup>2</sup> Loveys et al.

<sup>3</sup> Parts of speech

<sup>4</sup> Sadness

<sup>5</sup> Negative emotion

<sup>6</sup> Overall affect

<sup>7</sup> Verb

<sup>8</sup> Past focus

<sup>9</sup> <http://liwc.wpengin.com/how-it-works>

<sup>10</sup> Semantic

<sup>11</sup> <https://wordnet.princeton.edu>

<sup>12</sup> Wilson et al.

<sup>13</sup> Thelwall et al.

<sup>14</sup> Bollen et al.

<sup>15</sup> Durahim and Coşkun

<sup>16</sup> Subjective sentences

<sup>17</sup> Agents

<sup>18</sup> Direct subjective expressions

<sup>19</sup> Speech events


<sup>20</sup> Classification

<sup>21</sup> Clustering

<sup>22</sup> Sequence labelling

<sup>23</sup> <http://mallet.cs.umass.edu>

<sup>24</sup> <http://sentistrength.wlv.ac.uk>



همچنین ابزارهای سفارشی برای تحلیل احساسات توسعه یافته‌اند و برخی تحقیقات برای این منظور از معیارهای عاطفی برای کلمات انگلیسی<sup>۱</sup> استفاده نمودند (برادلی و لانگ<sup>۲</sup>، ۱۹۹۹).

بعلاوه، در چند کار از تکنیک‌های مدل‌سازی موضوع<sup>۳</sup> مانند تخصیص پنهان دیریکله<sup>۴</sup> (*LDA*) به‌عنوان یک روش مفید و قدرتمند برای ایجاد مدل‌های موضوعی و بخشی از تجزیه و تحلیل محتوا برای آشکارسازی موضوعات نهفته در پست‌های کاربر استفاده شده است (پائول و دردز<sup>۵</sup>، ۲۰۱۱؛ جی و همکاران<sup>۶</sup>، ۲۰۱۸). مدل‌سازی موضوع روشی برای تجزیه و تحلیل حجم زیادی از متن بدون برچسب، برای کشف ساختارهای معنایی مخفی است؛ که در آن «موضوع» شامل خوشه‌ای از کلمات است که اغلب با هم رخ می‌دهند. در واقع مدل‌های موضوع با استفاده از سرنخ‌های متنی، کلماتی با معانی مشابه را به یکدیگر متصل و کلماتی با معانی مختلف را از یکدیگر تفکیک می‌کنند. بنابراین *LDA*، موضوعات پنهان را بر اساس توزیع کلمه و سپس تخصیص موضوع به هر سند تحلیل می‌کند (بلی و همکاران<sup>۷</sup>، ۲۰۰۳). از دیگر ابزارهای موجود در این زمینه *Part-of-speech Tagger* است که با برچسب‌گذاری هر کلمه از متن، نقش آن کلمه را مشخص می‌کند<sup>۸</sup>.

مرحله انتخاب ویژگی، زیرمجموعه‌ای مرتبط از ویژگی‌های موجود را که قادر به پیش‌بینی علائم اختلالات روانی هستند با اجتناب از بیش‌برازش<sup>۹</sup> جداسازی می‌کند. هدف از تجزیه و تحلیل‌های آماری<sup>۱۰</sup> معمولاً کشف مجموعه پارامترهایی است که می‌توانند افراد دارای اختلال را از سایر افراد متمایز کنند؛ از جمله موارد استفاده شده در تحقیقات مرتبط می‌توان به ضریب همبستگی پیرسون<sup>۱۱</sup>، ضریب همبستگی رتبه اسپیرمن<sup>۱۲</sup> و آزمون یو-مان-ویتنی<sup>۱۳</sup> اشاره کرد. همچنین در بررسی‌ها جهت کاهش ابعاد ویژگی‌ها، از روش‌های تحلیل مولفه‌های اصلی (*PCA*)<sup>۱۴</sup>، *PCA* تصادفی<sup>۱۵</sup>، شبکه عصبی پیچشی<sup>۱۶</sup> با روش خودرمزگذار متقابل<sup>۱۷</sup>، روش گام‌به‌گام حریصانه روبه‌جلو<sup>۱۸</sup>، رگرسیون لجستیک دودویی<sup>۱۹</sup>، روش نسبت بهره<sup>۲۰</sup> و روش نجات<sup>۲۱</sup> نیز استفاده می‌شود. بعلاوه چند تحقیق محدود، استفاده از روش‌های مختلف یادگیری ماشین را برای یافتن ویژگی‌های مرتبط مورد بررسی قرار دادند (هوآنگ و همکاران<sup>۲۲</sup>، ۲۰۱۴؛ وانگ و همکاران<sup>۲۳</sup>، ۲۰۲۰). به این ترتیب برای ورود به مرحله ساخت مدل، پس از پیش‌پردازش داده‌ها، مراحل استخراج ویژگی جهت انتخاب ویژگی‌های مفید و پر اهمیت صورت می‌گیرد. در این مرحله با استفاده از رویکردهای انتخاب ویژگی و به‌منظور کاهش زمان آموزش، سهولت تفسیر، بهبود احتمال تعمیم<sup>۲۴</sup> و جلوگیری از بیش‌برازش، زیرمجموعه‌ای از ویژگی‌های مرتبط انتخاب خواهند شد.

### ۳-۴- ساخت مدل پیش‌بینی

در این مرحله با استفاده از ویژگی‌های منتخب و برچسب‌های دسته، یک مدل طبقه‌بندی باینری با نظارت آموزش داده می‌شود تا بتوان با استفاده از الگوهای آموخته شده، برچسب دسته را برای مجموعه داده‌های دیده نشده پیش‌بینی نمود. لازم به توضیح است که توسعه روش‌های یادگیری محور اصلی این پژوهش نیست، بلکه هدف از این تحقیق کشف و مطالعه ویژگی‌های جدیدی است که می‌توانند در آموزش مدل طبقه‌بندی مورد استفاده قرار گیرند و منجر به کشف الگوها و روابط پنهان در داده‌ها شوند. متداول‌ترین روش‌های یادگیری ماشین برای پیش‌بینی اختلال روانی، ماشین بردار پشتیبان<sup>۲۵</sup> (*SVM*) با هسته‌های<sup>۲۶</sup> متفاوت مانند خطی<sup>۲۷</sup> و تابع پایه شعاعی<sup>۲۸</sup> (*RBF*) (تسوگاو و همکاران، ۲۰۱۵؛ دی چاندھاری و همکاران، ۲۰۱۳؛ کانگ و همکاران<sup>۲۹</sup>، ۲۰۱۶؛ وانگ و همکاران، ۲۰۱۷؛ پروتیک پیترو و همکاران<sup>۳۰</sup>، ۲۰۱۵؛ برنپ و همکاران<sup>۳۱</sup>، ۲۰۱۵؛ نگوین و همکاران<sup>۳۲</sup>، ۲۰۱۴)، انواع متفاوت رگرسیون<sup>۳۳</sup> مانند خطی، لگاریتمی خطی<sup>۳۴</sup>

<sup>1</sup> Affective norms for english words

<sup>2</sup> Bradley and Lang

<sup>3</sup> Topic modeling

<sup>4</sup> Latent Dirichlet Allocation

<sup>5</sup> Paul and Dredze

<sup>6</sup> Ji et al.

<sup>7</sup> Blei et al.

<sup>8</sup> <https://nlp.stanford.edu/software/tagger.shtml>

<sup>9</sup> Overfitting

<sup>10</sup> Statistical analysis

<sup>11</sup> Pearson's correlation coefficient

<sup>12</sup> Spearman rank

<sup>13</sup> Mann-whitney U test

<sup>14</sup> Principal component analysis

<sup>15</sup> Randomized principal component analysis

<sup>16</sup> Convolutional Neural Network (CNN)

<sup>17</sup> Cross-autoencoder

<sup>18</sup> Forward greedy stepwise

<sup>19</sup> Binary logistic regression

<sup>20</sup> Gain ratio

<sup>21</sup> Relief

<sup>22</sup> Huang et al.

<sup>23</sup> Wang et al.

<sup>24</sup> Generalization

<sup>25</sup> Support vector machine

<sup>26</sup> Kernel

<sup>27</sup> Linear

<sup>28</sup> Radial basis function

<sup>29</sup> Kang et al.

<sup>30</sup> Preoțiu-Pietro et al.

<sup>31</sup> Burnap et al.

<sup>32</sup> Nguyen et al.

<sup>33</sup> Regression

<sup>34</sup> Log-linear



و لجستیک<sup>۱</sup> (کویر اسمیت و همکاران، ۲۰۱۴؛ یین و همکاران<sup>۲</sup>، ۲۰۱۹؛ هو و همکاران<sup>۳</sup>، ۲۰۱۵؛ کویر اسمیت و همکاران، ۲۰۱۶؛ گوآن و همکاران<sup>۴</sup>، ۲۰۱۵)، بیز ساده<sup>۵</sup> (هوآنگ و همکاران، ۲۰۱۴؛ وانگ و همکاران، ۲۰۱۷؛ نگوین و همکاران، ۲۰۱۴)، درخت تصمیم<sup>۶</sup> (هوآنگ و همکاران، ۲۰۱۴؛ نگوین و همکاران، ۲۰۱۴) و جنگل تصادفی<sup>۷</sup> (سراویا و همکاران، ۲۰۱۶؛ هوآنگ و همکاران، ۲۰۱۴؛ اورابی و همکاران<sup>۸</sup>، ۲۰۱۸) هستند. همچنین در چند تحقیق از رویکردهای یادگیری عمیق برای تشخیص افراد مبتلا به افسردگی (وانگ و همکاران، ۲۰۲۰؛ ونگ<sup>۹</sup>، ۲۰۱۵) ورد استفاده قرار گیرند. برای ساخت یک مدل پیش‌گو، مجموعه‌ای از ویژگی‌ها با هدف یادگیری الگوها انتخاب شده و به‌عنوان داده‌های آموزشی<sup>۱۰</sup> الگوریتم‌های یادگیری ماشین در نظر گرفته می‌شوند. با توجه به اینکه در تحقیقات مورد مطالعه از مجموعه داده‌های حاوی برجسب استفاده شده، رویکرد مدنظر در تمام موارد یادگیری بانظارت است؛ تا مدل بتواند بر مبنای این داده‌ها، دسته ورودی‌های بدون برجسب را تشخیص دهد. از جمله مطرح‌ترین تکنیک‌های استفاده شده برای این منظور، به ترتیب فراوانی استفاده می‌توان سه گروه روش‌های مبتنی بر ماشین بردار پشتیبان، روش‌های مبتنی بر رگرسیون، بیز ساده و درخت‌های تصمیم را نام برد. در گام بعد، پس از ساخت و توسعه مدل پیش‌بینی، لازم است تا سازوکاری برای سنجش میزان دقت و اطمینان‌پذیری آن در نظر گرفته شود.

### ۵-۳- تأیید مدل

یافته‌ها دقت طبقه‌بندی<sup>۱۱</sup>، ماتریس درهم‌ریختگی، صحت<sup>۱۲</sup>، فراخوانی<sup>۱۳</sup> و معیار  $F1$  پراستفاده‌ترین معیارها و ابزارهای بصری‌سازی نتایج هستند که در ادبیات تحقیق برای ارزیابی عملکرد مدل یادگیری مورد استفاده قرار می‌گیرند. بنابراین پس از ساخت مدل، عملکرد آن با استفاده از مجموعه داده آزمایشی ارزیابی می‌شود. رایج‌ترین روش اعتبارسنجی، روش اعتبارسنجی متقابل<sup>۱۴</sup>  $n$ -fold است. در روش اعتبارسنجی متقابل به‌طورکلی یک دور از اعتبارسنجی ضربدری شامل افزایش داده‌ها به دو زیرمجموعه مکمل، انجام تحلیل بر روی یکی از آن زیرمجموعه‌ها (داده‌های آموزشی) و اعتبارسنجی تحلیل با استفاده از داده‌های مجموعه دیگر (داده‌های آزمون) انجام می‌شود. برای کاهش پراکندگی، عمل اعتبارسنجی چندین بار با افزایش داده‌ها مختلف صورت می‌گیرد و از نتایج اعتبارسنجی‌ها میانگین گرفته می‌شود. در اعتبارسنجی متقابل  $n$ -fold، داده‌ها به  $n$  زیرمجموعه افزایش می‌شوند و از این  $n$  زیرمجموعه، هر بار یکی برای اعتبارسنجی و  $n-1$  تای دیگر برای آموزش به‌کار می‌روند. این روال  $n$  بار تکرار می‌شود و همه داده‌ها دقیقاً یک‌بار برای آموزش و یک‌بار برای اعتبارسنجی استفاده می‌شوند. در نهایت میانگین نتیجه این  $n$  بار اعتبارسنجی، به‌عنوان یک تخمین نهایی برگزیده می‌شود (کولکاری<sup>۱۵</sup>، ۲۰۱۸). در مدل‌سازی پژوهش‌های انجام شده در زمینه تحقیق، عمدتاً روش اعتبارسنجی ده لایه و در برخی موارد پنج لایه استفاده شده است. چند پژوهش نیز از  $LOOCV$ <sup>۱۶</sup> که نوع دیگری از اعتبارسنجی متقابل است استفاده نموده‌اند (وانکولپ و همکاران، ۲۰۱۷). علاوه بر تقسیم داده به مجموعه داده‌های آموزش و آزمون، برخی مطالعات با جمع‌آوری مجموعه داده جدید و به‌وسیله مقایسه نتایج پیش‌بینی با مجموعه‌ای از آمار شناخته‌شده (مانند نرخ افسردگی در شهرهای ایالات متحده، بررسی رضایت دانشجویان و درصد نشاط ملی ناخالص<sup>۱۷</sup>) به ارزیابی دقت مدل خود پرداختند. با بررسی توزیع اختلالات روان در پژوهش‌های مرتبط در می‌یابیم که عمده مقالات، بر مسئله افسردگی متمرکز هستند که نشان دهنده اهمیت این اختلال در بین اختلالات روانی است (وانکولپ و همکاران، ۲۰۱۷). کولکاری<sup>۱۸</sup>، در تحقیق خود با توجه به اینکه تشخیص افسردگی از رسانه‌های اجتماعی به‌عنوان یک مسئله طبقه‌بندی در زمینه پردازش زبان طبیعی مطرح می‌شود، به بررسی روش‌های پردازش زبان طبیعی موفق در استخراج اطلاعات از متن، برای بهبود تشخیص افسردگی پرداخت. روش‌های پردازش زبان طبیعی استخراج ویژگی را با هدف بازنمایی سند<sup>۱۸</sup> انجام می‌دهند. موضوع قابل توجه در تشخیص افسردگی از طریق رسانه‌های اجتماعی، کمبود داده برای کاربران مبتلا و اغتشاش<sup>۱۹</sup> ذاتی داده‌ها است. به همین منظور کولکاری<sup>۲۰</sup> استفاده از بازنمایی‌های توزیع شده لغت ( $DTRs$ ) را برای استفاده در روش‌های یادگیری ماشین بانظارت بررسی کرد تا بتواند در محیط رسانه‌های اجتماعی بازنمایی مناسبی داشته باشد و در نهایت کاربران هدف را درست طبقه‌بندی کند. نتایج ارزیابی او نشان داد  $DTRs$

<sup>1</sup> Logistic

<sup>2</sup> Yin et al.

<sup>3</sup> Hu et al.

<sup>4</sup> Guan et al.

<sup>5</sup> Naïve Bayes

<sup>6</sup> Decision tree

<sup>7</sup> Random forest

<sup>8</sup> Orabi et al.

<sup>9</sup> Wong

<sup>10</sup> Train dataset

<sup>11</sup> Accuracy

<sup>12</sup> Precision

<sup>13</sup> Recall

<sup>14</sup> Cross-validation

<sup>15</sup> Kulkarni

<sup>16</sup> Leave-one-out cross-validation

<sup>17</sup> Gross national happiness (GNH)

<sup>18</sup> Document representation

<sup>19</sup> Noise

<sup>20</sup> Distributed term representations (DTRs)



می‌تواند کمی مؤثرتر از روش‌های بازنمایی سنتی مانند کیسه‌کلمات<sup>۱</sup> (BOW) و بازنمایی بر اساس تعبیه کلمه<sup>۲</sup> عصبی عمل می‌کند. او همچنین ادعا می‌کند که بر اساس معیار جدید هر می<sup>۳</sup> در بازنمایی سند، در تشخیص زود هنگام افسردگی به پایین‌ترین میزان خطای تشخیص ریسک زود هنگام<sup>۴</sup> (ERDE) رسیده است (کوپر اسمیت و همکاران، ۲۰۱۴). کوپر اسمیت و همکارانش (۲۰۱۴) نیز نشان دادند که استفاده از روش‌های پردازش زبان طبیعی روی داده‌های اجتماعی، اختلالات روانی خاص مانند اضطراب پس از سانحه، افسردگی، اختلال دوقطبی و اختلال عاطفی فصلی (SAD) را افشا می‌کند. آن‌ها همچنان تأکید کردند که الگوهای مربوط به زبان، استفاده از ضمائر اول شخص، کلمات بیانگر احساس عصبانیت<sup>۵</sup> و احساسات منفی گوناگون با اختلالات روانی رابطه زیادی دارند (پنه بیکر و همکاران<sup>۶</sup>، ۲۰۱۵) که بخشی از این نتایج با استفاده از لوک (محمد و تورنی<sup>۷</sup>، ۲۰۱۳) تحلیل شده است. با این حال، به غیر از پست‌ها، اطلاعات دیگری (مانند شرح حال کاربر<sup>۸</sup>) در داده‌های اجتماعی وجود دارند که می‌توانند مورد بررسی و تحلیل قرار گیرند.

#### ۴- پیکربندی و تحلیل تجربی

بر مبنای گزارش مقالات پیشین، تعداد کم شرکت‌کنندگان، هزینه قابل توجه و فرآیند بسیار زمان‌بر، از مشکلات عمده به دست آوردن داده به واسطه رضایت کاربر است (کوپر اسمیت و همکاران، ۲۰۱۴؛ ریزولا و همکاران، ۲۰۲۰). همچنین، کاربران دارای اختلال، تمایل چندانی به مشارکت در پروژه‌های تحقیقاتی ندارند. علاوه بر این، در ارزیابی این روش شکاف‌های زمانی زیادی وجود دارد و با توجه به اینکه شناسایی عوامل خطر مرتبط با اختلالات روان در بسیاری از موارد نیازمند مداخلات فوری است، این مسئله توسعه برنامه‌های مداخله مؤثر را محدود می‌کند (دی چاندھاری، ۲۰۱۳). به همین دلیل بسیاری از محققان پیشنهاد می‌کنند که از عبارات قاعده به همراه حاشیه‌نویسی انسانی برای ارزیابی استفاده شود؛ البته ما معتقدیم می‌توان با ارائه مکانیزمی خودکار، باز هم این روند را تسهیل نمود. گذشته از این، اکثر تحقیقات گذشته، تحلیل خود را روی بخش کوچکی از جامعه (با تعریف گروهی مشخص) انجام داده‌اند و از این رو بسیاری از روش‌های ارائه شده، کاربرد عملی در دنیای واقعی ندارند. بعلاوه، انواع متنوعی از داده‌ها، با ویژگی‌های متفاوت در شبکه‌های اجتماعی وجود دارند که تاکنون مورد بررسی قرار نگرفته‌اند، در حالی که عمده تحقیقات بر داده‌های متنی و تنها پست‌های کاربر متمرکز هستند. به همین جهت در این بخش از مقاله سعی می‌شود با ارائه چارچوبی کاربردی جهت پیش‌بینی اختلال روانی مشخص و همین‌طور تجزیه و تحلیل نتایج با مدل‌ها و معیارهای متفاوت به بخشی از این خلأ پاسخ داده شود.

##### ۴-۱- مجموعه داده

در میان شبکه‌های اجتماعی، توئیتر همواره یکی از مناسب‌ترین منابع جهت تحلیل بوده و همان‌طور که در سوابق تحقیق شرح داده شد، طیف وسیعی از تحقیقات روی آن صورت گرفته است. ما نیز به منظور شناسایی ویژگی‌های کاربران آنلاین مبتلا به افسردگی، از توئیتر به عنوان منبع داده استفاده می‌کنیم. ویژگی‌های مورد مطالعه این پژوهش متن شرح حال<sup>۹</sup> و توئیتهای<sup>۱۰</sup> کاربر هستند؛ به طوری که پس از فاز جمع‌آوری و پیش‌پردازش لازم، تحلیل هر کدام به صورت جداگانه انجام شده و سپس مورد ارزیابی مقایسه‌ای قرار می‌گیرند. از آنجاکه بسیاری از کاربران تمایل دارند اطلاعات مربوط به وضعیت اوضاع روانی خود را به صورت عمومی افشا کنند، در این گام بر مبنای اظهارات کاربر، ابتدا پست‌های تشخیصی را با استفاده از عبارات با قاعده (مطابق نمونه گزارش‌های تشخیص استفاده شده در تحقیقات گذشته (کوپر اسمیت و همکاران، ۲۰۱۴؛ لوسادا و کرسناتی، ۲۰۱۶؛ ریزولا و همکاران، ۲۰۲۰) و با بهره‌گیری از API توئیتر جمع‌آوری می‌کنیم. در گام بعد لازم است اطمینان حاصل شود که توئیتهای جمع‌آوری شده، گزارشی واقعی از وضعیت فرد باشند و کاربر آنلاین واقعاً از بیماری روانی رنج ببرد. برچسب‌گذاری دستی توسط حاشیه‌نویسان انسانی، از جمله پزشکان یا متخصصان قابل اعتماد و جمع‌سپاری می‌تواند گزینه‌های ایده آلی باشند، اما منجر به صرف زمان بسیار زیاد شده و عملاً در حجم بالای داده امکان‌پذیر نیست. با این حال، برخی از مراحل پیش‌پردازش می‌تواند به شکل قابل توجهی به دستیابی به داده‌های هدف کمک کند. ریزولا و همکاران (۲۰۲۰) اخیراً روشی را برای جمع‌آوری خودکار نمونه پست‌های افسردگی در انجمن‌های ردیت<sup>۱۱</sup> ارائه داده‌اند. آن‌ها دوروش ابتکاری برای پالایش پست‌های غیر مفید کاربر و مشخص کردن علائم افسردگی پیشنهاد دادند. اولین روش اکتشافی، امتیاز قطبیت احساسات<sup>۱۲</sup> را در نظر

<sup>1</sup> Bag-of-words (BoW)

<sup>2</sup> Word embedding

<sup>3</sup> Pyramidal

<sup>4</sup> Early risk detection error (ERDE)

<sup>5</sup> Anger words

<sup>6</sup> Pennebaker et al.

<sup>7</sup> Mohammad and Turney

<sup>8</sup> User bio description

<sup>9</sup> Bio

<sup>10</sup> Tweets

<sup>11</sup> <https://reddit.com>

<sup>12</sup> Sentiment polarity score



می‌گیرد و روش دوم، از شباهت موضوعی<sup>۱</sup> و رده‌بندی<sup>۲</sup> افسردگی استفاده می‌کند. نتایج به دست آمده نشان می‌دهد که روش اول (قطبیت احساسات) از دقت قابل قبولی برخوردار است. با الهام از این آزمایش، گام اول پیش‌پردازش را اجرا می‌کنیم و در گام دوم با استفاده از واژه‌نامه احساسات *NRC* (معروف به *EmoLex*) (چوآ و همکاران<sup>۳</sup>، ۲۰۱۹) که ارتباط بین فهرستی از کلمات انگلیسی و هشت احساس پایه (ترس<sup>۴</sup>، انتظار<sup>۵</sup>، اعتماد<sup>۶</sup>، شادی<sup>۷</sup>، خشم<sup>۸</sup>، تعجب<sup>۹</sup>، غم و انزجار) را مشخص می‌کند، موارد حاوی احساس غم و انزجار را در نظر می‌گیریم. کاربران کاندید می‌توانند به‌عنوان گزینه‌های احتمالی برای تشکیل گروه تشخیص داده شده ( $D^+$ ) در نظر گرفته شوند. با توجه به اینکه هر کاربر در توییت با یک شناسه<sup>۱۰</sup> شناسایی می‌شود، در مرحله بعد اطلاعات مورد نیاز کاربران کاندید توسط شناسه منحصر به فرد آن‌ها به وسیله *API* جمع‌آوری می‌شود. به شیوه‌ای مشابه، برای انتخاب مجموعه‌ای از کاربران که دارای اختلال افسردگی نبوده و نماینده عموم جامعه هستند ( $D^-$ )، توییت‌های حاوی کلمه کلیدی "the" (بدون در نظر گرفتن معیارهای قطبیت و احساسات) جمع‌آوری می‌شوند و کاربران خروجی این روند را به‌عنوان کاندیدهای گروه کنترل در نظر می‌گیریم ( $D_{ii}$ ). جهت اطمینان از عدم تداخل در روند آموزش کاربران همپوشان از مجموعه  $D^-$  حذف می‌شوند. با در نظر گرفتن قوانین بازیابی *API* و گام‌های پیش‌پردازش شرح داده شده، مجموعه  $D^+$  شامل ۱۱,۸۹۰,۶۳۲ توییت و ۵۵۳ متن شرح حال و مجموعه  $D^-$  شامل ۱۶,۶۲۳,۱۶۴ توییت و ۵۷۰ متن شرح حال جهت تجزیه و تحلیل خواهد بود.

#### ۴-۲- استخراج اطلاعات زبانی

بر مبنای این ایده که کلماتی که شخص استفاده می‌کند بیانگر افکار، عواطف و وضعیت ذهنی او هستند، در این بخش ما دو نوع ویژگی زبانی را مورد بررسی قرار می‌دهیم: ویژگی‌های لوک و مدل‌های زبانی. ما از لوک به‌عنوان بخشی از تجزیه و تحلیل و همچنین به‌عنوان منبعی برای ویژگی‌ها استفاده می‌کنیم. همان‌طور که در فصل قبل توضیح داده شد، لوک ابزاری برای تجزیه و تحلیل متن، ارزیابی بخش‌های روانشناختی، شناختی و ساختاری متن معینی است که از فرهنگ لغتی متشکل از کلمات و دسته‌های طبقه‌بندی شده متفاوت (به شکل مجموعه و زیرمجموعه) استفاده می‌کند؛ در نتیجه هر موجودیت ورودی به لوک می‌تواند به یک یا بیش از یک دسته تعلق داشته باشد. به این ترتیب در این فاز بعد از مراحل پیش‌پردازش لازم، کیسه‌ای از لغات یا *BoW* را بر مبنای متن شرح حال و توییت‌های جمع‌آوری شده، به صورت جداگانه تولید می‌کنیم و به همراه *BoVW* از بخش قبل، به‌عنوان چهار ورودی این مرحله در نظر می‌گیریم. در نتیجه، ما امتیاز دسته‌های مربوط به هر ورودی را خواهیم داشت. انتظار داریم که *BoW* و *BoVW* در تجزیه و تحلیل لوک، نشانه‌های معناداری را در تشخیص گروه کاربران (از منظر روانشناسی) مشخص کنند، وابستگی معنادار متفاوتی بین آن‌ها وجود داشته باشد و یا دارای نقاط مکمل یکدیگر باشند. همچنین، ما از مدل‌های زبان *n-gram* استفاده می‌کنیم تا احتمال توالی کارکترها یا لغات را تخمین بزنیم. به دلیل کوتاه‌نویسی‌ها<sup>۱۱</sup> و غلط‌های املائی<sup>۱۲</sup> در متون موجود در شبکه‌های اجتماعی (به‌ویژه توییت)، استفاده از رویکردهای سنتی مبتنی بر کلمه نمی‌تواند نتیجه مطلوبی به همراه داشته باشد. به همین جهت، مجدداً پس از انجام پیش‌پردازش لازم (مانند حذف کلمات اضافه)، از دو مدل زبانی استفاده می‌کنیم: *n-gram* کارکتر، شامل *2-grams* و *4-grams* و *n-gram* لغت، شامل *unigrams* و *bigrams*. ما همچنین برای استخراج ویژگی‌ها از تکنیک *tf-idf* بهره می‌گیریم و در مرحله بعد، از این ویژگی‌ها در واحد طبقه‌بندی استفاده خواهیم نمود.

#### ۴-۳- طبقه‌بندی

ما انتظار داریم که چارچوب ارائه شده، با حصول دقت مناسب در مدل‌های پیش‌بینی، نقاط قوت ویژگی‌های منتخب را دنبال کند. در این بخش، به‌منظور ارزیابی روش پیشنهادی، علاوه بر مقایسه عملکرد ویژگی‌های تعریف شده، طبقه‌بندی رگرسیون لجستیک<sup>۱۳</sup> را به‌عنوان طبقه‌بندی معیار<sup>۱۴</sup> ایجاد نموده و با پیاده‌سازی روش‌های طبقه‌بندی دیگر و بررسی دقت پیش‌بینی، روش ارائه شده را مورد آزمایش قرار می‌دهیم و در نهایت یافته‌ها را ارائه خواهیم نمود. برای بررسی جامع‌تر، علاوه بر طبقه‌بندی معیار، ما سه روش طبقه‌بندی

<sup>1</sup> Topical similarity

<sup>2</sup> Taxonomy

<sup>3</sup> Chua et al.

<sup>4</sup> Fear

<sup>5</sup> Anticipation

<sup>6</sup> Trust

<sup>7</sup> Joy

<sup>8</sup> Anger

<sup>9</sup> Surprise


<sup>10</sup> ID

<sup>11</sup> Shortening

<sup>12</sup> Spelling errors

<sup>13</sup> Logistic regression

<sup>14</sup> Benchmark



ماشین بردار پشتیبان خطی<sup>۱</sup>، کت بوست<sup>۲</sup> و پرسپترون چند لایه<sup>۳</sup> (MLP) را روی ویژگی‌ها اعمال نموده و برای پیاده‌سازی هر طبقه‌بندی از روش اعتبارسنجی متقابل 10-fold جهت تأیید نتایج استفاده می‌کنیم. در نهایت برای ارزیابی تکنیک‌های طبقه‌بندی از معیارهای ارزیابی استاندارد مانند دقت برآورد و امتیاز FI، شامل صحت و فراخوانی استفاده می‌شود که به ماتریس درهم‌ریختگی و اطلاعات مربوط به نتایج پیش‌بینی متکی هستند و به شرح زیر تعریف می‌شوند.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = TPR = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

معیارهای ارزیابی تعریف شده، در جدول ۱، شکل ۳ و شکل ۴ ارائه شده‌اند که به ما امکان بررسی دقیق خروجی‌ها را می‌دهند. همان‌طور که در نتایج مشخص شده، بهترین دقت با استفاده از تجزیه و تحلیل توییت‌ها و به طور ویژه در الگوریتم کت بوست (۹۸٪) حاصل شده است و در ویژگی شرح حال طبقه‌بندی MLP (۹۲٪)، بیشترین دقت را کسب نموده است. امتیاز به دست آمده در FI نیز نشان دهنده همین ترتیب است. برای نگاه دقیق‌تر به جزئیات تجزیه و تحلیل ویژگی‌ها در نوع ویژگی توییت، شکل ۳ را در نظر می‌گیریم که در آن بالاترین دقت به دست آمده در آزمایش اعتبارسنجی متقابل ترسیم شده است.

جدول ۱- مقایسه خروجی روش‌های تجزیه و تحلیل متفاوت.

Table 1- Comparison of different analysis methods.

Classifier	Methods	Tweets		Bio Description	
		Accuracy	F1	Accuracy	F1
Logistic Regression	LIWC	0.67	0.68	0.61	0.58
	Char2	0.65	0.64	0.58	0.58
Linear SVM	Char4	0.71	0.70	0.67	0.62
	Word1	0.75	0.75	0.63	0.54
	Word2	0.75	0.75	0.54	0.38
	LIWC	0.72	0.74	0.60	0.59
Catboost	Char2	0.64	0.63	0.58	0.57
	Char4	0.71	0.70	0.71	0.70
	Word1	0.74	0.74	0.76	0.77
	Word2	0.74	0.74	0.54	0.42
MLP	LIWC	0.73	0.73	0.58	0.57
	Char2	0.65	0.64	0.59	0.58
	Char4	0.74	0.73	0.67	0.63
	Word1	0.88	0.87	0.60	0.50
	Word2	0.91	0.89	0.53	0.27
	LIWC	0.73	0.74	0.60	0.57
Mood	Char2	0.61	0.61	0.53	0.52
	Char4	0.68	0.68	0.83	0.82
	Word1	0.70	0.70	0.72	0.69
	Word2	0.70	0.70	0.52	0.62

همان‌طور که از نتایج مشخص است، *Bigram* کلمه به‌عنوان یک ویژگی واحد، تا حد محسوسی نسبت به سایر ویژگی‌ها برتری دارد. *Unigram* کلمه با دقت ۹۵٪، لوک و *Four-gram* کاراکتر با دقت ۸۱٪، و در نهایت *Bigram* کاراکتر با ۷۱٪ نیز به ترتیب در جایگاه‌های بعدی قرار می‌گیرند. بنابراین می‌توان نتیجه گرفت که الف) توییت‌های اخیر بازیابی شده از کاربر می‌توانند ویژگی قدرتمندی در تشخیص حالت روحی<sup>۴</sup> کاربر باشد و ب) در صورتی که در شرایطی نتوانیم بنا به دلایلی مانند دسترسی محدود و یا تعداد کم به توییت‌ها دسترسی پیدا کنیم، اطلاعات عمومی کاربر می‌توانند نقش مؤثری در تشخیص وضعیت کاربر داشته باشند. نکته جالب‌تر اینجاست که متن شرح حال در عین کوتاهی می‌تواند علائم افسردگی را با دقت ۹۲٪ نشان دهد؛ در حالی که نه تنها در مقایسه با توییت‌ها، جزء اطلاعات

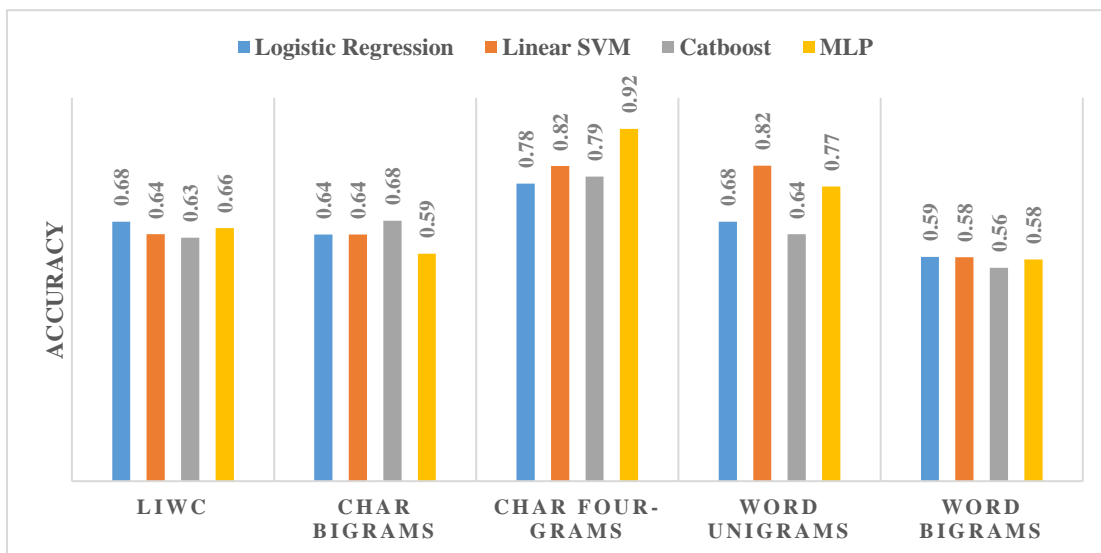
<sup>1</sup> Linear SVM

<sup>2</sup> Catboost

<sup>3</sup> Multilayer perceptron

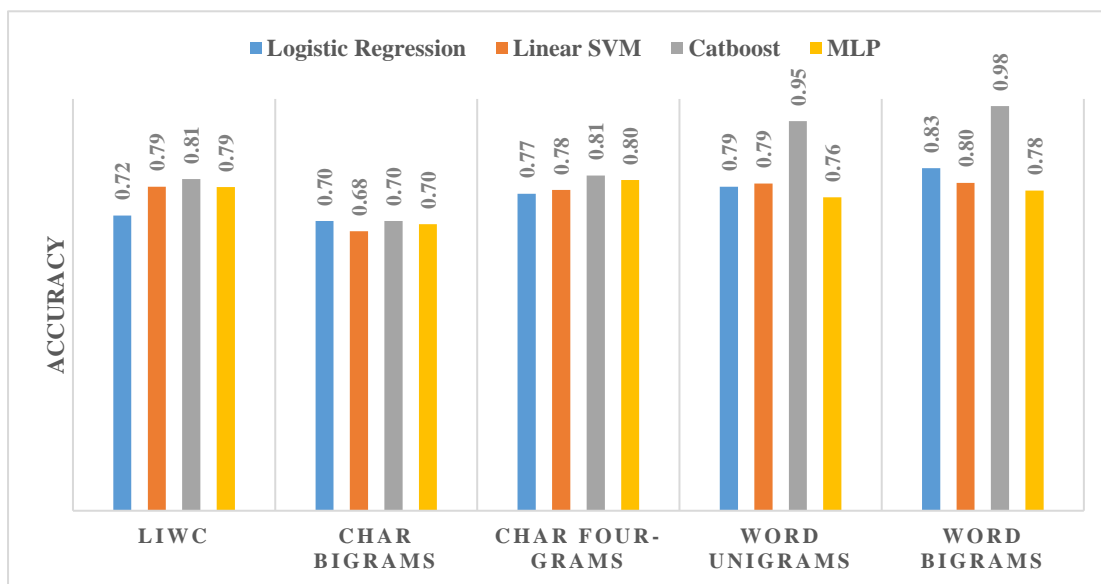
<sup>4</sup> Mood

عمومی نمایه کاربری است و در دسترس قرار دارد، بلکه در مقایسه با سایر روندها حجم به مراتب کمتری داشته (ماکزیمم ۲۸۰ کاراکتر) و به طبع آن سازوکار تحلیل کوتاه‌تری را می‌طلبد. برای درک بهتر تأثیر این ویژگی، روش‌های متفاوت تجزیه و تحلیل را در شکل ۴ مقایسه نمودیم.



شکل ۳- مقایسه دقت به دست آمده در روش‌های متفاوت تجزیه و تحلیل توییت.

Figure 3- Comparison of the accuracy achieved by tweets analyzing methods.



شکل ۴- مقایسه دقت به دست آمده در روش‌های متفاوت تجزیه و تحلیل شرح حال.

Figure 4- Comparison of the accuracy achieved by bios analyzing methods.

بر این اساس، *four-gram* کاراکتر با دقت بالای ۹۲٪ با استفاده از *MLP*، می‌تواند ویژگی قابل قبولی جهت پیش‌بینی باشد. *Unigram* کلمه با دقت ۸۲٪ با استفاده از بردار ماشین پشتیبان و در نهایت *Bigram* کاراکتر با دقت ۶۸٪ با استفاده از کت‌بوست به ترتیب در جایگاه‌های بعدی قرار می‌گیرند. همچنین مشاهده شد که ویژگی‌های استخراج شده از لوک می‌تواند در تفکیک دو گروه تأثیرگذار باشد اما ویژگی مطلوبی در مقایسه با سایر روش‌های تحلیل نیست. در نهایت، می‌توان نتیجه گرفت که ویژگی‌های *bigram* کلمه در توییت‌ها و *four-gram* کاراکتر در شرح حال، دو مورد از قوی‌ترین ویژگی‌ها برای پیش‌بینی علائم افسردگی در رویکرد مورد بحث هستند و می‌توانند عملکرد مناسبی در تفکیک کلاس‌های هدف داشته باشند.





نتایج تجزیه و تحلیل تأیید می‌کنند که جمع‌آوری خودکار داده‌ها می‌تواند یک روش عملی و مقرون‌به‌صرفه، با صرف زمانی بسیار کوتاه‌تر نسبت به روش‌های سنتی باشد. این رویکرد همچنان می‌تواند برای مسائل مشابه (مانند چارچوب‌های پیشگیری از آسیب به خود و خودکشی یا بررسی سایر اختلالات روانی) با کمی تغییر در گام پالایش اولیه مورد استفاده قرار گیرد. این چارچوب همچنین می‌تواند به‌عنوان یک روش سبک وزن<sup>۱</sup> در قالب سیستم‌های پیشیبیان تصمیم‌بالی، برای تسهیل تصمیمات تشخیصی متخصصان و یا به‌عنوان ابزاری برای پیشگیری و مداخلات در بستر شبکه‌های اجتماعی استفاده شود.

هدف از این مقاله شناسایی نقشه راه درباره چگونگی پیش‌بینی اختلالات روانی از طریق کاوش داده‌های اجتماعی بود که می‌تواند منجر به ایجاد سیستم‌های تصمیم‌یار روانشناختی و تسهیل فرآیند تشخیص شود. همچنین اشاره شد که خروجی پژوهش‌های این زمینه می‌تواند گام مؤثری در توسعه ابزارهای پیشگیری از آسیب در سکوهاى اجتماعى تلقى شوند. در این تحقیق ضمن تشریح مفاهیم پایه و ادبیات تحقیق، تازه‌ترین پژوهش‌های زمینه مورد بحث و بررسی قرار گرفت و با شناخت چالش‌ها و مسائل باز حوزه، مثالی کاربردی با تکیه بر جمع‌آوری خودکار نمونه‌ها ارائه شد. در روش پیاده‌سازی شده، پس از گام جمع‌آوری و پالایش اولیه، ویژگی‌های مورد نظر از مجموعه داده استخراج شد و مراحل پیش‌پردازش به صورت جداگانه روی مجموعه‌ها اعمال شد. سپس ضمن تکرار یافته‌های قبلی به منظور صحت سنجی تحلیل، تلاش شد ارتباط بین علائم افسردگی، ویژگی‌های نمایه و به طور مشخص استفاده از زبان از طریق تجزیه و تحلیل واژه‌نامه و تکنیک‌های پردازش زبان طبیعی مشخص شود. در این بررسی ویژگی متن شرح حال نیز به‌عنوان ویژگی عمومی در دسترس مورد تجزیه و تحلیل قرار گرفت که پیش از این در تحقیقات مرتبط بررسی نشده بودند. در نهایت، نتایج پیاده‌سازی و یافته‌ها الگوی مشخصی را بین کاربران دو گروه نمایش دادند که می‌تواند ملاک ارزیابی‌های آینده قرار گیرد. ما معتقدیم که مفاهیم ارائه شده می‌توانند در گام اول منجر به شکل‌گیری مجموعه داده‌ای جهت پیش‌برد تحقیقات این حوزه شده و تحلیل اطلاعات متفاوت نمایه کاربر را ممکن سازد، و در گام بعد، مبتلایان بالقوه افسردگی را بر اساس اطلاعات استخراج شده از نمایه (نه تنها توییت‌ها) شناسایی کند. همچنین با توجه به نتایج حاصل از این مطالعه و اثبات مفهوم، به نظر می‌رسد می‌توان از روش پیشنهادی به‌عنوان یک ابزار مکمل برای نظارت بر وضعیت سلامت روانی افرادی که به طور مکرر در سکوهاى اجتماعى (به طور خاص توییت) فعالیت دارند، با اهداف گوناگون استفاده نمود.

در پایان اشاره می‌کنیم علاوه بر متن شرح حال و توییت‌ها، اطلاعات دیگری نیز وجود دارند که ما معتقدیم می‌توانند دقت تشخیص را افزایش دهند. این اطلاعات شامل هشتگ‌ها و اطلاعات زمینه هستند. تجزیه و تحلیل ساختار شبکه‌های اجتماعی (از دیدگاه تحلیل گراف) نیز ابزار حائز اهمیت دیگری است که می‌تواند برای بررسی شیوع بیماری‌های روانی در بین کاربران آنلاین مورد استفاده قرار گیرد. بنابراین تحقیقات آینده ما بر سایر انواع داده و تجزیه و تحلیل بیشتر ویژگی‌های مشتق شده متمرکز خواهد بود.

## تعارض با منافع

نویسندگان اعلام می‌دارند که هیچ تضادی در منافع در مورد انتشار این مقاله وجود ندارد.

## منابع

- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent dirichlet allocation. *Journal of machine learning research*, 3(Jan), 993-1022.
- Bollen, J., Gonçalves, B., Ruan, G., & Mao, H. (2011). Happiness is assortative in online social networks. *Artificial life*, 17(3), 237-251.
- Bradley, M. M., & Lang, P. J. (1999). *Affective norms for English words (ANEW): instruction manual and affective ratings*. Retrieved from <https://pdodds.w3.uvm.edu/teaching/courses/2009-08UVM-300/docs/others/everything/bradley1999a.pdf>
- Braithwaite, S. R., Giraud-Carrier, C., West, J., Barnes, M. D., & Hanson, C. L. (2016). Validating machine learning algorithms for Twitter data against established measures of suicidality. *JMIR mental health*, 3(2), e4822. <https://mental.jmir.org/2016/2/e21>
- Bumap, P., Colombo, W., & Scourfield, J. (2015). Machine classification and analysis of suicide-related communication on Twitter. *Proceedings of the 26th ACM conference on hypertext & social media* (pp. 75-84). Association for Computing Machinery. <https://doi.org/10.1145/2700171.2791023>
- Callison-Burch, V., Guadagno, J., & Davis, A. (2017). *Facebook Newsroom: building a safer community with new suicide prevention tools*. Retrieved from <https://newsroom.fb.com/news/2017/03/building-a-safer-community-with-newsuicideprevention-tools>

<sup>1</sup> Lightweight



- Chen, X., Sykora, M. D., Jackson, T. W., & Elayan, S. (2018, April). What about mood swings: Identifying depression on twitter with temporal measures of emotions. *Companion proceedings of the the web conference 2018* (pp. 1653-1660). <https://doi.org/10.1145/3184558.3191624>
- Chen, X., Sykora, M., Jackson, T., Elayan, S., & Munir, F. (2018). Tweeting your mental health: an exploration of different classifiers and features with emotional signals in identifying mental health conditions. *Proceedings of the 51st Hawaii international conference on system sciences* (pp. 3320-3328). <http://hdl.handle.net/10125/50309>
- Chua, C. E. H., Storey, V. C., Li, X., & Kaul, M. (2019). Developing insights from social media using semantic lexical chains to mine short text structures. *Decision support systems*, 127, 113142. <https://doi.org/10.1016/j.dss.2019.113142>
- Coppersmith, G., Dredze, M., & Harman, C. (2014, June). Quantifying mental health signals in Twitter. *Proceedings of the workshop on computational linguistics and clinical psychology: from linguistic signal to clinical reality* (pp. 51-60). <https://aclanthology.org/W14-3207.pdf>
- Coppersmith, G., Harman, C., & Dredze, M. (2014, May). Measuring post traumatic stress disorder in Twitter. *Proceedings of the eighth international AAAI conference on weblogs and social media* (pp. 579-582). <https://www.aaai.org/ocs/index.php/ICWSM/ICWSM14/paper/viewPaper/8079>
- Coppersmith, G., Leary, R., Crutchley, P., & Fine, A. (2018). Natural language processing of social media as screening for suicide risk. *Biomedical informatics insights*, 10, 1-11. <https://doi.org/10.1177/1178222618792860>
- Coppersmith, G., Ngo, K., Leary, R., & Wood, A. (2016, June). Exploratory analysis of social media prior to a suicide attempt. *Proceedings of the third workshop on computational linguistics and clinical psychology* (pp. 106-117). Association for Computational Linguistics.
- De Choudhury, M. (2013, October). Role of social media in tackling challenges in mental health. *Proceedings of the 2nd international workshop on socially-aware multimedia* (pp. 49-52). New York, NY, United States. Association for Computing Machinery. <https://doi.org/10.1145/2509916.2509921>
- De Choudhury, M., Counts, S., & Horvitz, E. (2013, May). Social media as a measurement tool of depression in populations. *Proceedings of the 5th annual ACM web science conference* (pp. 47-56). Association for Computing Machinery.
- Du, J., Zhang, Y., Luo, J., Jia, Y., Wei, Q., Tao, C., & Xu, H. (2018). Extracting psychiatric stressors for suicide from social media using deep learning. *BMC medical informatics and decision making*, 18(2), 77-87.
- Durahim, A. O., & Coşkun, M. (2015). # iamhappybecause: Gross National Happiness through Twitter analysis and big data. *Technological forecasting and social change*, 99, 92-105. <https://doi.org/10.1016/j.techfore.2015.06.035>
- Gao, J., Zheng, P., Jia, Y., Chen, H., Mao, Y., Chen, S., ... & Dai, J. (2020). Mental health problems and social media exposure during COVID-19 outbreak. *Plos one*, 15(4), e0231924. <https://doi.org/10.1371/journal.pone.0231924>
- Guan, L., Hao, B., Cheng, Q., Yip, P. S., & Zhu, T. (2015). Identifying Chinese microblog users with high suicide probability using internet-based profile and linguistic features: classification model. *JMIR mental health*, 2(2), e4227. DOI: [10.2196/mental.4227](https://doi.org/10.2196/mental.4227)
- Hu, Q., Li, A., Heng, F., Li, J., & Zhu, T. (2015, December). Predicting depression of social media user on different observation windows. *2015 IEEE/WIC/ACM international conference on web intelligence and intelligent agent technology (WI-IAT)* (Vol. 1, pp. 361-364). IEEE.
- Huang, X., Zhang, L., Chiu, D., Liu, T., Li, X., & Zhu, T. (2014, December). Detecting suicidal ideation in Chinese microblogs with psychological lexicons. *2014 IEEE 11th intl conf on ubiquitous intelligence and computing and 2014 IEEE 11th intl conf on autonomic and trusted computing and 2014 IEEE 14th intl conf on scalable computing and communications and its associated workshops* (pp. 844-849). IEEE. DOI: [10.1109/UIC-ATC-ScalCom.2014.48](https://doi.org/10.1109/UIC-ATC-ScalCom.2014.48)
- Ji, S., Yu, C. P., Fung, S. F., Pan, S., & Long, G. (2018). Supervised learning for suicidal ideation detection in online user content. *Complexity*, 2018. <https://doi.org/10.1155/2018/6157249>
- Kang, K., Yoon, C., & Kim, E. Y. (2016, January). Identifying depressive users in Twitter using multimodal analysis. *2016 international conference on big data and smart computing (BigComp)* (pp. 231-238). IEEE.
- Kaplan, A. M., & Haenlein, M. (2010). Users of the world, unite! the challenges and opportunities of Social Media. *Business horizons*, 53(1), 59-68.
- Kulkarni, A. B. K. (2018). *Early detection of depression* (Doctoral Thesis, University of Houston). Retrieved from <http://hdl.handle.net/10657/3089>
- Liu, P., Tov, W., Kosinski, M., Stillwell, D. J., & Qiu, L. (2015). Do Facebook status updates reflect subjective well-being?. *Cyberpsychology, behavior, and social networking*, 18(7), 373-379.
- Losada, D. E., & Crestani, F. (2016, September). A test collection for research on depression and language use. *International conference of the cross-language evaluation forum for European languages* (pp. 28-39). Springer, Cham.
- Losada, D. E., Crestani, F., & Parapar, J. (2020, April). Erisk 2020: Self-harm and depression challenges. *European conference on information retrieval* (pp. 557-563). Springer, Cham.
- Loveys, K., Crutchley, P., Wyatt, E., & Coppersmith, G. (2017, August). Small but mighty: affective micropatterns for quantifying mental health from social media language. *Proceedings of the fourth workshop on computational linguistics and clinical psychology—from linguistic signal to clinical reality* (pp. 85-95). Association for Computational Linguistics.
- Ma, L., Wang, Z., & Zhang, Y. (2017, May). Extracting depression symptoms from social networks and web blogs via text mining. *International symposium on bioinformatics research and applications* (pp. 325-330). Springer, Cham.
- Martínez-Castaño, R., Pichel, J. C., & Losada, D. E. (2020). A big data platform for real time analysis of signs of depression in social media. *International journal of environmental research and public health*, 17(13), 4752. <https://doi.org/10.3390/ijerph17134752>
- Mohammad, S. M., & Turney, P. D. (2013). Crowdsourcing a word-emotion association lexicon. *Computational intelligence*, 29(3), 436-465.
- Moreno, M. A., Jelenchick, L. A., Egan, K. G., Cox, E., Young, H., Gannon, K. E., & Becker, T. (2011). Feeling bad on Facebook: Depression disclosures by college students on a social networking site. *Depression and anxiety*, 28(6), 447-455.
- Nguyen, T., Phung, D., Dao, B., Venkatesh, S., & Berk, M. (2014). Affective and content analysis of online depression communities. *IEEE transactions on affective computing*, 5(3), 217-226.
- Orabi, A. H., Buddhitha, P., Orabi, M. H., & Inkpen, D. (2018, June). Deep learning for depression detection of twitter users. *Proceedings of the fifth workshop on computational linguistics and clinical psychology: from keyboard to clinic* (pp. 88-97). Association for Computational Linguistics.
- Park, A., Bowling, J., Shaw, G., Li, C., & Chen, S. (2019). Adopting social media for improving health: opportunities and challenges. *North Carolina medical journal*, 80(4), 240-243.
- Paul, M., & Dredze, M. (2011). You are what you tweet: analyzing twitter for public health. *Proceedings of the international AAAI conference on web and social media* (Vol. 5, No. 1, pp. 265-272). <https://ojs.aaai.org/index.php/ICWSM/article/view/14137>

- Pennebaker, J. W., Boyd, R. L., Jordan, K., & Blackburn, K. (2015). *The development and psychometric properties of LIWC2015*. Retrieved from <http://hdl.handle.net/2152/31333>
- Preoțiu-Pietro, D., Sap, M., Schwartz, H. A., & Ungar, L. (2015). Mental illness detection at the world well-being project for the CLPsych 2015 shared task. *Proceedings of the 2nd workshop on computational linguistics and clinical psychology: from linguistic signal to clinical reality* (pp. 40-45). Association for Computational Linguistics.
- Ríssola, E. A., Aliannejadi, M., & Crestani, F. (2020, April). Beyond modelling: understanding mental disorders in online social media. *European conference on information retrieval* (pp. 296-310). Springer, Cham.
- Ríssola, E. A., Bahrainian, S. A., & Crestani, F. (2020, July). A dataset for research on depression in social media. *Proceedings of the 28th ACM conference on user modeling, adaptation and personalization* (pp. 338-342). Association for Computing Machinery.
- Samani, Z. R., Guntuku, S. C., Moghaddam, M. E., Preoțiu-Pietro, D., & Ungar, L. H. (2018). Cross-platform and cross-interaction study of user personality based on images on Twitter and Flickr. *PLoS one*, 13(7), e0198660. <https://doi.org/10.1371/journal.pone.0198660>
- Saravia, E., Chang, C. H., De Lorenzo, R. J., & Chen, Y. S. (2016, August). MIDAS: Mental illness detection and analysis via social media. *2016 IEEE/ACM international conference on advances in social networks analysis and mining (ASONAM)* (pp. 1418-1421). IEEE.
- Schwartz, H. A., Sap, M., Kern, M. L., Eichstaedt, J. C., Kapelner, A., Agrawal, M., ... & Ungar, L. H. (2016). Predicting individual well-being through the language of social media. *Proceedings of the Pacific Symposium* (pp. 516-527). Biocomputing. [https://doi.org/10.1142/9789814749411\\_0047](https://doi.org/10.1142/9789814749411_0047)
- Sun, S., Luo, C., & Chen, J. (2017). A review of natural language processing techniques for opinion mining systems. *Information fusion*, 36, 10-25.
- Thelwall, M., Buckley, K., Paltoglou, G., Cai, D., & Kappas, A. (2010). Sentiment strength detection in short informal text. *Journal of the American society for information science and technology*, 61(12), 2544-2558.
- Tsugawa, S., Kikuchi, Y., Kishino, F., Nakajima, K., Itoh, Y., & Ohsaki, H. (2015, April). Recognizing depression from twitter activity. *Proceedings of the 33rd annual ACM conference on human factors in computing systems* (pp. 3187-3196). Association for Computing Machinery.
- Wang, T., Brede, M., Ianni, A., & Mentzakis, E. (2017, February). Detecting and characterizing eating-disorder communities on social media. *Proceedings of the tenth ACM international conference on web search and data mining* (pp. 91-100). Association for Computing Machinery. <https://doi.org/10.1145/3018661.3018706>
- Wang, Y., Wang, Z., Li, C., Zhang, Y., & Wang, H. (2020). *A multitask deep learning approach for user depression detection on sina weibo*. Retrieved from <https://doi.org/10.48550/arXiv.2008.11708>
- Wilson, T., Hoffmann, P., Somasundaran, S., Kessler, J., Wiebe, J., Choi, Y., ... & Patwardhan, S. (2005, October). Opinionfinder: a system for subjectivity analysis. *Proceedings of HLT/EMNLP 2005 interactive demonstrations* (pp. 34-35). Vancouver. <https://aclanthology.org/H05-2018.pdf>
- Wong, T. T. (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern recognition*, 48(9), 2839-2846.
- Wongkoblaph, A., Vaddillo, M. A., & Curcin, V. (2017). Researching mental health disorders in the era of social media: systematic review. *Journal of medical internet research*, 19(6), e7215. <https://www.jmir.org/2017/6/e228/>
- Yin, Z., Sulieman, L. M., & Malin, B. A. (2019). A systematic literature review of machine learning in online personal health data. *Journal of the American medical informatics association*, 26(6), 561-576.

