



Semnan University

Research Article

Journal of Modeling in Engineering

Journal homepage: <https://modelling.semnan.ac.ir/>



Classification of social media posts during the Corona crisis based on their polarity

Hanie Tandorost¹, Samira Abbasi^{1*}, Fatemeh Amiri²

1. Department of Biomedical Engineering, Hamedan University of Technology, Hamedan, Iran.

2. Department of Computer Engineering, Hamedan University of Technology, Hamedan, Iran

*Corresponding Author: samira.abbasi@gmail.com

PAPER INFO

Paper history:

Received: 30 December 2022

Revised: 08 April 2023

Accepted: 26 April 2023

Keywords:

Social media

Corona virus

Natural language processing (NLP)

Deep learning

Polarity.

ABSTRACT

The Iranian people were confronted with a range of emotions during the Covid-19 crisis, which they shared on social media platforms. Social media played a crucial role in disseminating information and reflecting public sentiment during the pandemic. Consequently, governments and health organizations worldwide recognized the importance of analyzing social media data. Many researchers have examined these data using different approaches worldwide. This study focuses on the polarity analysis and classification of messages posted on social media during the COVID-19 crisis. The study analyzed messages shared by Persian-language users on social networks using natural language processing and deep learning techniques. Various deep learning methods, including convolutional neural networks (CNN), long short-term memory (LSTM), and fuzzy-LSTM were used to classify the data as positive or negative polarity. The three-layer deep convolutional neural network achieved the highest accuracy of 72.29%. Finally, a comprehensive comparison of the different networks used was conducted across multiple aspects.

© 2023 Published by Semnan University Press.

DOI: <https://doi.org/10.22075/jme.2023.29412.2384>

How to cite this article:

Tandorost, H., Abbasi, S., & Amiri, F. (2023). Classification of social media posts during the Corona crisis based on their polarity. *Journal of Modeling in Engineering*, 21(74), 81-93. doi: 10.22075/jme.2023.29412.2384

کلاس بندی پیام های منتشر شده در شبکه های اجتماعی در بحران کرونا بر اساس قطبیت آنها

حانیه تندرست^۱، سمیرا عباسی^{۱*} و فاطمه امیری^۲

اطلاعات مقاله	چکیده
<p>نوع مقاله: پژوهشی دریافت مقاله: ۱۴۰۱/۱۰/۰۹ بازنگری مقاله: ۱۴۰۲/۰۱/۱۹ پذیرش مقاله: ۱۴۰۲/۰۲/۰۶</p>	<p>بحران کرونا مردم ایران را با طیف گسترده ای از افکار و احساسات مثبت و منفی روبرو کرد. مردم این احساسات را در شبکه های اجتماعی به اشتراک می گذاشتند. شبکه های اجتماعی در دوران کرونا نقش بسیار مهمی در انتشار اطلاعات و بازتاب احساسات مردم داشته اند. بررسی این داده های شبکه های اجتماعی برای دولت ها و سازمان های بهداشت در سراسر جهان حائز اهمیت است. به همین خاطر پژوهش های زیادی به بررسی این داده ها با رویکردهای مختلف در سراسر جهان پرداختند. در این مقاله نیز به تحلیل قطبیت و کلاس بندی پیام های منتشر شده در شبکه های اجتماعی در بحران کرونا پرداخته شد. برای این منظور پیام هایی که کاربران فارسی زبان در این شبکه ها به اشتراک گذاشتند، بررسی شدند. برای کلاس بندی داده های موجود از روش های پردازش زبان طبیعی و روش های یادگیری عمیق استفاده شد. برای کلاس بندی پیام ها با محتوای مثبت و منفی، روش های یادگیری عمیق مختلفی با معماری های متفاوت (شامل شبکه های کانولوشنی، شبکه های بازگشتی عمیق با حافظه و فازی-بازگشتی عمیق با حافظه) با توجه به داده های موجود اعمال شد تا بتوانیم به بهترین نتیجه ممکن دست یابیم. بهترین نتیجه با استفاده از شبکه های عمیق کانولوشنی سه لایه به دست آمد که صحت آن ۷۲.۲۹ بود. در نهایت، یک مقایسه کلی از جنبه های مختلف، روی شبکه های استفاده شده انجام شد.</p>
<p>واژگان کلیدی: شبکه های اجتماعی، ویروس کرونا، پردازش زبان طبیعی، یادگیری عمیق، قطبیت.</p>	

۱- مقدمه

اکثراً در قالب خبر و برای اطلاع رسانی بودند. بررسی محتوای جملات بر اساس قطبیت آن ها (مثبت، منفی) نوعی تعریف در حیطه تحلیل احساسات محسوب می شود [۳]. پیام ها از نظر قطبیت به سه گروه تقسیم بندی می شوند: منفی، مثبت و خنثی. پیام هایی با ماهیت ترس، خشم، اضطراب و ... را پیام های با مفهوم منفی تلقی می کنیم. پیام ها در قالب روحیه دادن به عموم جامعه و کادر درمان، ابراز همدردی، و در مواقعی تمسخر کردن این بیماری منحوس را پیام هایی با محتوای مثبت تلقی می کنیم. در این میان پیام هایی هم هستند که احساس خاصی را به خواننده منتقل نمی کنند، که این گروه از پیام ها را به عنوان خنثی در نظر می گیریم. برای مثال اخبار

با گسترش اینترنت، شبکه های اجتماعی جزء جدایی ناپذیر زندگی انسان ها شده اند و بستری مناسب فراهم کرده اند تا افراد بتوانند احساسات خود را بیان کنند و نظرات خود را به راحتی به اشتراک بگذارند [۱]. با افزایش استفاده از شبکه های اجتماعی و به اشتراک گذاشتن عقاید و نظرات در این شبکه ها، تحلیل احساسات در جنبه های مختلف زندگی انسان ها وارد شده است و نقش موثری پیدا کرده است [۱، ۲]. با شروع پاندمی کرونا فعالیت افراد در این شبکه ها افزایش یافته است. از پزشکان و افراد متخصص حوزه سلامت تا مردم عادی نظرات مختلفی را در شبکه های اجتماعی به اشتراک گذاشتند. البته این پیام ها

* پست الکترونیک نویسنده مسئول: samira.abbasi@gmail.com

۱. گروه مهندسی پزشکی، دانشگاه صنعتی همدان، همدان، ایران
 ۲. گروه مهندسی کامپیوتر، دانشگاه صنعتی همدان، همدان، ایران

¹ Polarity

کلاس بندی آن‌ها، از روش‌های یادگیری عمیق [۹] استفاده شده است. همچنین، در این مقاله عملکرد شبکه‌های کانوولوشنی و بازگشتی با معماری‌های مختلف، برای کلاس‌بندی قطبیت پیام‌ها بررسی شده است. در نهایت، نتایج بدست آمده از دو معماری متفاوت از شبکه‌های کانوولوشنی و دو معماری بازگشتی با هم مقایسه شده‌اند. نتایج نشان می‌دهد شبکه کانوولوشنی در تحلیل قطبیت پیام‌های فارسی موفق‌تر عمل نموده است.

۱-۲- کارهای مرتبط

با توجه به اهمیت پردازش زبان طبیعی، این حوزه همیشه مورد توجه محققان بوده است به همین دلیل فعالیت‌های پژوهشی زیادی در این حوزه انجام شده است. بخشی از فعالیت‌های این حوزه مربوط به طبقه‌بندی متن است، طبقه‌بندی متن عموماً در دو سطح متن و سطح جمله انجام می‌شود [۱۲]. برای طبقه‌بندی در سطح متن، یک پیام را به عنوان متنی که بیانگر یک نظر کاملاً مثبت یا کاملاً منفی است، طبقه‌بندی می‌کند. این نوع طبقه‌بندی، کل متن را به عنوان واحد اطلاعات پایه در نظر می‌گیرد. در طبقه‌بندی سطح جمله، هر جمله از یک متن طبقه‌بندی می‌شود. روش متداول این است که فرد ابتدا جمله را به عنوان یک جمله اظهار نظر شده یا اظهار نظر نشده طبقه‌بندی کند (به این فرآیند طبقه‌بندی ساجکتیو^۱ می‌گویند)، سپس جملات اظهار نظر شده حاصل، به عنوان جملاتی که بیانگر نظرات مثبت یا نظرات منفی هستند، طبقه‌بندی می‌شوند. طبقه‌بندی سطح جمله را همچنین می‌توان به عنوان یک مساله طبقه‌بندی سه کلاسه فرمول‌بندی کرد، به این معنا که می‌توان یک جمله را به عنوان مثبت، منفی یا خنثی طبقه‌بندی کرد [۱۲].

در گذشته بیشتر از روش‌های دستی استخراج ویژگی برای کلاس‌بندی استفاده می‌شد [۱۳] اما با معرفی شبکه‌های یادگیری عمیق، محققین این روش‌ها را بهینه یافتند زیرا با استفاده از این روش‌ها در وقت و هزینه‌های نیروی انسانی صرفه جویی می‌شود [۱۴]. ساز و کار این شبکه‌ها براساس یادگیری از نمونه‌های آموزش است. این شبکه‌ها بیشتر مانند ذهن انسان عمل می‌کنند و می‌توانند به صورت خودکار ویژگی‌های مورد نیاز را از تعداد بالای داده استخراج کنند ولی ایرادی که به آن‌ها وارد است این است که برای

علمی و پژوهشی و پیام‌هایی که احساسات متناقضی را در غالب یک پیام منتقل می‌کنند را می‌توان پیام با قطبیت خنثی در نظر گرفت [۴].

امروزه بررسی قطبیت پیام‌های ثبت شده و تحلیل آن‌ها می‌تواند نقشی اساسی در زمینه‌های مختلف مثلاً در کسب و کارهای اینترنتی داشته باشد [۴]. چنین بررسی‌هایی در سیاست نیز مورد توجه است زیرا به دولتمردان در شناخت بیشتر جامعه آماری کشور کمک می‌کند [۵]. حتی این نیاز در حوزه سلامت نیز کاملاً احساس می‌شود و می‌تواند متخصصان این حوزه را به درک بهتری از شرایط جامعه برساند. تحلیل پیام‌ها در دوران شیوع بیماری کرونا نیز مورد توجه محققان قرار گرفته است و این مطالعات در تصمیم‌گیری و برنامه‌ریزی بهتر و دقیق‌تر برای مقابله با مشکلات ناشی از ویروس کرونا قابل استفاده بوده‌اند. بررسی پیام‌های ثبت شده در شبکه‌های اجتماعی با موضوع ویروس کرونا به زبان‌های مختلف و در کشورهای مختلف انجام شده است. تعدادی از این مطالعات به کلاس‌بندی پیام‌ها بر اساس قطبیت آن‌ها با استفاده از روش‌های متفاوتی پرداختند [۶-۸]. یکی از ابزارهای متداول در این حوزه استفاده از روش‌های یادگیری عمیق [۹] است، یادگیری عمیق یکی از تکنیک‌های قدرتمند یادگیری ماشین است که نتایج مطلوبی در حوزه‌های مختلف مانند پردازش سیگنال، تصویر و ... داشته است [۹]. همچنین در پردازش زبان طبیعی و داده‌های متنی نیز برای تحلیل احساسات، قطبیت و ... عملکرد قابل قبولی ارائه داده است [۱۰].

در خصوص زبان فارسی نیز مطالعه مشابهی روی داده‌های استخراج شده از دیجی کالا انجام شده است و نظرات مردم در مورد فروش کالاها در این شرکت از نظر قطبیت بررسی شده است [۱۱]. اما مطالعات کمی روی پیام‌های فارسی مربوط به کرونا انجام شده است. هیچ یک از مطالعات انجام شده به تحلیل قطبیت در پیام‌های فارسی با استفاده از روش‌های یادگیری ماشین نپرداخته‌اند. از اینرو، در این مقاله سعی شده تا قطبیت پیام‌های فارسی مربوط به کرونا بررسی شود.

این پیام‌ها از شبکه‌های اجتماعی (اینستاگرام، توییتر، تلگرام و کانال‌های خبری داخلی) در دوران شیوع کرونا جمع‌آوری شده‌اند. برای تحلیل قطبیت پیام‌ها و

^۱ Subjective

فازی می‌تواند برای بهبود نتایج مفید باشد [۲۳]، اما باید در نظر داشت که نتایج کلاس‌بندی با استفاده از این شبکه‌ها می‌تواند متفاوت باشد و به عواملی مانند نوع داده وابسته است. به همین دلیل در مطالعه حاضر، از روش‌های یادگیری عمیق متفاوتی استفاده شده و نتایج آنها مقایسه شده‌اند.

لازم به ذکر است در دوران کرونا تحقیقات زیادی روی داده‌های متنی جمع‌آوری شده از شبکه‌های اجتماعی انجام شده است. این پژوهش‌ها روی داده‌هایی به زبان‌های مختلف از جمله انگلیسی [۲۵، ۲۶]، چینی [۲۷] و ... در سراسر دنیا بوده‌اند. پژوهش‌هایی روی داده‌های فارسی زبان نیز انجام شده است [۲۸، ۲۹] که بیشتر از روش‌های بدون نظارت و البته روش‌های خوشه‌بندی استفاده کرده‌اند [۲۸، ۲۹].

در یکی از پژوهش‌هایی [۳۰] که به زبان فارسی انجام شده است محققان دو روش را به کار بردند، آن‌ها ترکیبی از حاشیه‌نویسی دستی از بین پیام‌هایی که به صورت تصادفی انتخاب شده بودند و ابزارهای مدل‌سازی موضوع را برای طبقه‌بندی استفاده کردند. آن‌ها از ابزار مدل‌سازی تخصیص پنهان دریکله^{۱۰} استفاده کردند و موضوعاتی که بیشترین تکرار را داشتند مشخص کردند. در این میان بیشترین موضوع در مورد مسائل مربوط به قرنطینه گزارش شد [۳۰]. در تحقیقی دیگر [۳۱] پژوهشگران داده‌های مربوط به واکسیناسیون کرونا را بررسی نمودند. آن‌ها نظر مردم را در مورد واکسن‌های ساخت داخل و خارج بررسی کردند و به این نتیجه رسیدند که نظر مردم ایران در مورد واکسن-های ساخت داخل و خارج از کشور تقریباً یکی است. برای این منظور آن‌ها از روش بدون نظارت و پیش آموزش استفاده کردند [۳۱].

اما پژوهشی در زبان فارسی به تحلیل کلی احساسات پیام-های منتشر شده در دوران کرونا با محوریت قطبیت آن نپرداخته است. از اینرو در پژوهش حاضر، تمرکز روی کلاس‌بندی داده‌ها براساس قطبیت آن‌ها است.

۲- روش

هدف ما در این تحقیق کلاس‌بندی پیام‌های منتشر شده

آموزش این شبکه‌ها به تعداد داده نسبتاً قابل توجهی نیاز است و داشتن داده مناسب نیز همیشه یک دغدغه در این حوزه بوده است.

شبکه‌های یادگیری عمیقی که عموماً برای کلاس‌بندی متن استفاده می‌شوند شامل شبکه‌های کانولوشنی^۱ (CNN) [۱۵]، حافظه بلند مدت کوتاه^۲ (LSTM) [۱۶]، تلفیق این شبکه‌ها [۱۷]، و در مواردی یادگیری انتقالی^۳ [۱۸] است. شبکه‌های کانولوشنی نوعی از شبکه‌های یادگیری عمیق هستند که به سرعت بین محققان این حوزه به محبوبیت رسیدند [۱۹]. این شبکه‌ها مانند سایر شبکه‌های عصبی^۴ [۲۰] از لایه‌های نورونی با قابلیت یادگیری تشکیل شده‌اند. معماری این شبکه‌ها به صورت کلی به این صورت است که اغلب از یک لایه کانولوشن با تعداد و اندازه فیلتر مشخص استفاده می‌شود، لایه بعد تابع فعال‌ساز^۵ است، یک لایه پولینگ^۶ و در آخر یک لایه کاملاً متصل^۷ استفاده می‌شود. البته معماری این شبکه می‌تواند کاملاً منحصر به فرد طراحی شود. این شبکه‌ها برای ورودی ماتریسی به خوبی کار می‌کنند و نتایج قابل قبولی دارند.

شبکه‌های بازگشتی^۸ نوع دیگری از شبکه‌های عصبی هستند که اغلب برای داده‌های سری زمانی مانند داده‌های متنی استفاده می‌شوند. اما مشکلی که در استفاده از این‌ها وجود داشت این بود که برای متون و جملات طولانی کاربردی نبودند و نتایج قابل قبولی نداشتند، به همین دلیل شبکه‌های بازگشتی با حافظه معرفی شدند که عملکردشان روی داده‌های متنی بهتر بوده است. این شبکه‌ها بلوک حافظه (کوتاه و بلند مدت) دارند و معمولاً نسبت به شبکه‌های بازگشتی ساده عملکرد بهتری دارند. در این راستا محققان یک مدل حافظه بلند مدت کوتاه برای کلاس‌بندی ارائه کرده‌اند [۲۱، ۲۲]. شبکه‌های حافظه بلند مدت کوتاه نوعی از شبکه‌های بازگشتی محسوب می‌شوند. همچنین در مواردی می‌توان این شبکه‌ها را با منطق فازی ادغام کرد [۲۲]، که به این شبکه‌ها، شبکه‌های فازی عمیق^۹ می‌گویند [۲۳]. منطق فازی معمولاً برای کنترل عدم قطعیت و بهبود نتایج استفاده می‌شود [۲۴]. مطالعات در حوزه پردازش زبان طبیعی نیز نشان داده‌اند که تلفیق شبکه‌های عمیق و

⁶ Pooling layer

⁷ Fully connected layer

⁸ Recurrent neural network (RNN)

⁹ Neuro Fuzzy

¹⁰ Latent dirichlet allocation (LDA)

¹ Convolutional Neural Network (CNN)

² Long Short Term Memory (LSTM)

³ Transfer learning

⁴ Neural Network

⁵ Activation function

و بیش‌نمونه‌گیری^۲ [۳۳] استفاده شد. روش شبه نظارتی شبه‌برچسب زدن برای برچسب‌گذاری داده‌های بدون برچسب استفاده می‌شود. این روش زمانی استفاده می‌شود که به تعداد کافی داده برچسب‌دار موجود نباشد و همچنین تعداد زیادی داده بدون برچسب وجود داشته باشد که برچسب زدن دستی آن به دلیل صرف وقت و هزینه زیاد امکان‌پذیر نباشد. در این موارد می‌توان از این روش شبه نظارتی برای برچسب‌گذاری بهینه استفاده کرد [۳۴]. در این روش برچسب‌گذاری، شبکه‌ای روی داده‌های برچسب خورده آموزش داده می‌شود و از آن برای برچسب‌گذاری تعداد بیشتری از داده‌ها استفاده می‌شود و در نهایت از تلفیق داده‌های برچسب‌دار و داده‌هایی که با روش شبه-برچسب زدن به صورت شهودی برچسب‌گذاری شده‌اند، استفاده می‌شود [۳۵]. در این مقاله، با استفاده از این روش ۱۷۷۵ پیام دیگر برچسب‌گذاری و به داده‌های قبلی اضافه شدند که ۱۵۷۴ پیام متعلق به کلاس مثبت و ۲۰۱ پیام از آن‌ها متعلق به کلاس منفی هستند. این تعداد داده، به ۲۳۰۴ پیام برچسب‌دار قبلی، اضافه شدند. در نهایت، داده‌ها شامل ۴۰۷۹ پیام برچسب‌دار هستند که همان‌طور که گفته شد این افزایش داده و بالانس شدن کلاس‌ها می‌تواند در بهبود عملکرد شبکه بسیار موثر باشد.

همچنین از بیش‌نمونه‌گیری زمانی استفاده می‌شود که داده‌ها بالانس نباشند [۳۶]، متوازن کردن داده‌ها می‌تواند نتایج را تا حدی بهبود ببخشد [۳۷]. در داده‌های استفاده شده نهایی که شامل داده‌های دستی برچسب‌گذاری شده به علاوه داده‌های برچسب‌گذاری شده با روش شبه برچسب زدن است، توزیع داده‌های دو کلاس به این صورت می‌شود که کلاس منفی شامل ۱۷۱۱ پیام است در صورتی که تعداد پیام‌های کلاس مثبت ۲۳۶۷ پیام است. به همین دلیل از این روش برای متوازن کردن داده‌ها استفاده می‌کنیم. این روش قابلیت آن را دارد که داده‌هایی مشابه داده‌های موجود را به صورت تصادفی تولید کند تا کمبود داده در کلاس منفی را تا حدودی جبران کند.

۲-۱- پیش پردازش

داده‌هایی که از شبکه‌های اجتماعی جمع‌آوری می‌شوند اغلب داده‌های تمیزی نیستند و نیاز به پیش پردازش دارند تا برای کلاس‌بندی با شبکه عصبی مناسب باشند. از اینرو

در دوران کرونا براساس قطبیت آن‌ها (مثبت، منفی)، با استفاده از روش‌های یادگیری عمیق است.

در این راستا، از داده‌هایی استفاده می‌شود که همگی در دوران شیوع کرونا و با این مضمون جمع‌آوری شده‌اند. مجموعه داده استفاده شده در این پژوهش، با حمایت ستاد توسعه علوم شناختی در آزمایشگاه شبکه‌های اجتماعی دانشکده برق و کامپیوتر دانشگاه تهران جمع‌آوری شده است. پردازش و برچسب‌زنی دستی این مجموعه در آزمایشگاه پردازش زبان فارسی دانشکده کامپیوتر دانشگاه شهید بهشتی انجام شده است. براساس اعلام ستاد علوم شناختی، دوازده نفر سندها را برچسب زده‌اند. داده‌های مورد توجه این مقاله در یک چالش ملی با عنوان "شناخت و تحلیل گفتمان و رفتار جامعه ایرانی در بحران کرونا" استفاده شده است که توسط ستاد علوم شناختی ارائه شده است و به صورت عمومی در دسترس نیست. این دیتابیس شامل پست‌ها و خبرها در رابطه با کوید ۱۹ است که در بازه زمانی ۱ بهمن ماه ۱۳۹۸ تا ۱۰ اردیبهشت ۱۳۹۹ منتشر شده‌اند. این داده‌ها، به زبان فارسی هستند و از شبکه‌های اجتماعی مانند اینستاگرام، تلگرام، توئیتر استخراج شده‌اند. به هرکدام از این پیام‌ها یک سند گفته می‌شود. تعداد کل این داده‌ها ۶۳۳۹ پیام فارسی است که توسط ۱۲ نفر به صورت دستی برچسب‌گذاری و صحت‌سنجی شده‌اند و در دسته‌های مثبت، منفی، غم، شادی، ترس، فرهنگی، سیاسی، مذهبی، علمی و ... قرار گرفته‌اند. تعلق هر پیام به گروه مربوط به آن با عدد یک مشخص شده است و اگر پیام متعلق به آن گروه نباشد با صفر مشخص می‌شود. همچنین هر پیام می‌تواند چندین برچسب داشته باشد مثلاً هر دو برچسب غم و ترس را داشته باشد.

به دلیل کمبود داده‌های برچسب‌دار در این پژوهش ما فقط داده‌ها را بر اساس قطبیت آن‌ها کلاس‌بندی کردیم و دو کلاس کلی قطبیت مثبت و منفی را برای هر پیام در نظر گرفتیم. منظور از قطبیت مثبت/منفی این است که پیام محتوای مثبت/منفی دارد و بر روی خواننده اثر مثبت/منفی می‌گذارد. تعداد پیام‌ها با قطبیت مثبت ۷۹۳ و پیام‌ها با قطبیت منفی ۱۵۱۱ بود که تعداد خیلی کمی محسوب می‌شود. به منظور بهبود نتایج یادگیری و متوازن کردن داده‌های هر دو کلاس از دو روش شبه‌برچسب زدن^۱ [۳۲]

² Over sampling

¹ Pseudo-labeling

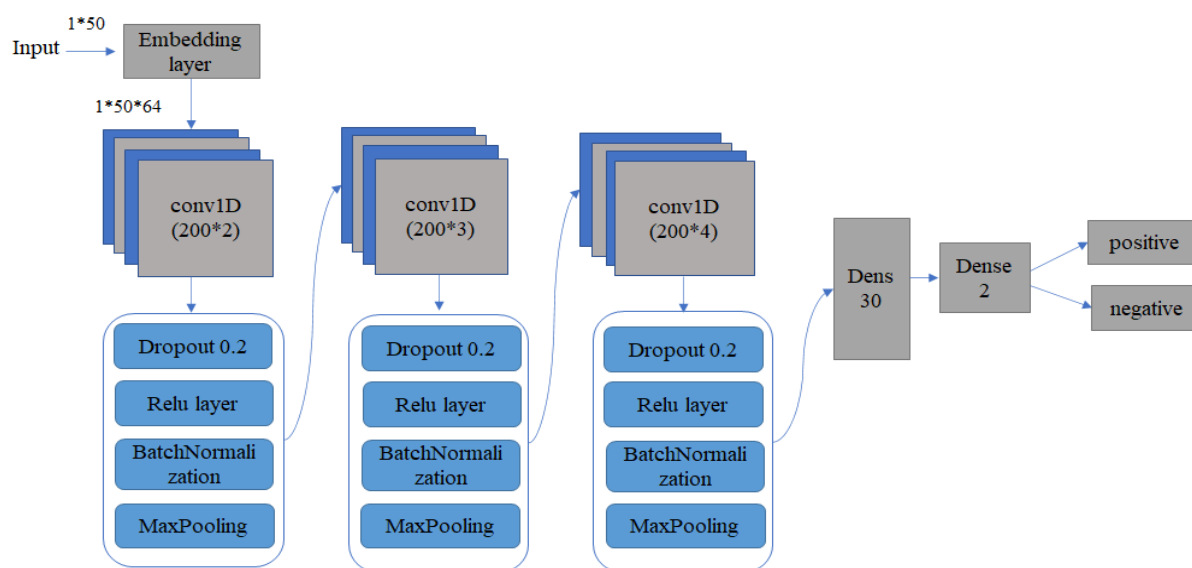
نهایت جملات را به شکل بردارها تعبیه خواهد کرد. به این صورت که به هر توکن، وزنی بر اساس محتوای آن کلمه داده می‌شود. پس از انجام مراحل ذکر شده، به برداری از اعداد با ابعاد یکسان رسیده که ورودی شبکه است.

۲-۲- کلاس بندی

پس از انجام پیش‌پردازش، داده‌ها بر اساس قطبیت مثبت و منفی کلاس‌بندی شدند. برای کلاس‌بندی ۱۰ درصد داده‌ها به عنوان تست و ۱۰ درصد برای ارزیابی^۵ در نظر گرفته شد. در نهایت، از شبکه‌های مختلفی برای کلاس-بندی داده‌ها استفاده شد. این شبکه‌ها شامل شبکه‌ی کانولوشنی با دو معماری متفاوت، حافظه بلند مدت کوتاه [41, 42]، FUZZY-LSTM بودند که همگی به دفعات در مقالات حوزه زبان طبیعی استفاده شده‌اند و اغلب عملکرد خوبی داشته‌اند [۴۳-۴۶].

۲-۲-۱- شبکه کانولوشنی

شبکه کانولوشنی [۴۷] نوعی از شبکه‌های یادگیری عمیق محسوب می‌شود که الگویی مطابق نورون‌های مغز انسان دارد. این شبکه‌ها معمولاً از لایه‌های کانولوشنی، پولینگ و لایه تماماً متصل تشکیل می‌شوند. هرکدام از این لایه‌ها در طول پروسه یادگیری نقش اساسی دارند. در این مقاله معماری‌های مختلف شبکه کانولوشنی بررسی شد و بهترین نتیجه با استفاده از معماری نشان داده شده در شکل (۱) بدست آمد.



شکل ۱- معماری شبکه کانولوشنی بهینه؛ این شبکه نسبت به سایر شبکه‌ها بهترین نتیجه را داشته است.

در این مقاله نیز پیش پردازش روی داده‌ها انجام شد. مراحل پیش پردازش عبارتند از: حذف تمامی کاراکترهای اضافی و لینک‌ها و ...، حذف کلمات توقف، ریشه‌یابی کلمات، نرمال‌سازی و توکن‌بندی.

ابتدا حروف ربطی و کاراکترهایی که معنی خاصی را در جمله منتقل نمی‌کنند و فقط بار محاسباتی را بیشتر می‌کنند، حذف شدند. سپس هشتگ‌های تکراری، آیدی‌های افراد، لینک‌ها، کلمات توقف و ... نیز حذف شدند. در ادامه مرحله نرمال‌سازی و توکن‌بندی داده‌ها انجام شد. برای این منظور از روش توکن‌کردن کلمات^۱ [۳۸] با کتابخانه کراس^۲ [۳۹] و از ماژول توکن‌کننده کراس^۳ استفاده می‌شود سپس به هر توکن، وزنی بر اساس محتوای آن کلمه داده می‌شود [۴۰] زیرا نیاز است متون به ساختاری عددی تبدیل شوند، چون شبکه‌های یادگیری عمیق امکان دریافت و پردازش داده متنی را ندارند و تنها اعداد می‌توانند به عنوان ورودی استفاده و پردازش شوند. پس باید هر جمله به شکل مجموعه‌های از کلمات درآمده و سپس هر کلمه به برداری از اعداد نگاشت شود. با استفاده از روش نگاشت کلمات^۴، این امکان به وجود می‌آید که کلماتی که از لحاظ مفهوم یا ظاهر شدن در جمله به یکدیگر نزدیک‌اند، در فضای چند بعدی نیز با بردارهایی نزدیک به یکدیگر بیان شوند. در این روش شبکه عصبی علاوه بر وظایف اصلی، در لایه نخست خود به جستجوی الگوها بر روی مجموعه داده پرداخته و طبق این الگوها کلمات و در

⁴ Word embedding

⁵ Validation

¹ Word Tokenization

² Keras

³ Keras Tokenizer

تعداد این فیلتر سائزها با سعی و خطا و آزمایش‌های مختلف به دست آمده است). در هر سه لایه از تابع فعال‌ساز relu و از $\text{BatchNormalization}$ نیز استفاده شد. در ادامه سه لایه متراکم با تعداد نورون‌های ۶۴، ۸، و ۲ قرار دادیم و در آخر از تابع فعال‌ساز Softmax استفاده کردیم. این معماری را CNN2 می‌نامیم.

۲-۲-۲- شبکه حافظه بلند مدت کوتاه

این شبکه نوعی شبکه بازگشتی محسوب می‌شود. از این شبکه‌های عمیق معمولاً برای کار با داده‌های سری زمانی استفاده می‌شود. معماری شبکه‌های حافظه بلند مدت کوتاه کمی با شبکه‌های بازگشتی ساده متفاوت است و دارای گیت‌های حافظه و فراموشی هستند. وظیفه این دو گیت نگهداری اطلاعات با اهمیت برای شبکه حذف اطلاعات می‌باشد. به همین دلیل این شبکه‌ها اغلب برای داده‌های سری زمانی که شامل داده‌هایی طولانی هستند خوب عمل می‌کنند و از محاسبات اضافه جلوگیری می‌کنند [۴۸].

شبکه LSTM استفاده شده در مطالعه حاضر شامل یک لایه دوسویه با ۲۰۰ نورون و همچنین لایه‌های GlobalMaxPooling و SpatialDropOut است.

۲-۲-۳- شبکه FUZZY-LSTM

شبکه‌های فازی عمیق، تلفیقی از شبکه‌های عصبی عمیق و لایه‌های فازی کننده^۵ و غیرفازی کننده^۶ هستند که اغلب برای بهبود عدم قطعیت استفاده می‌شوند [۲۴].

به این منظور ما شبکه LSTM که در مرحله قبل ذکر شد را با لایه‌های فازی کننده و غیرفازی کننده تلفیق کردیم. به این صورت که ورودی را به یک لایه دوسویه با ۲۰۰ نورون اعمال کردیم و سپس از لایه متراکم با ۲ و ۴ نورون و تابع فعال‌ساز سیگموئید^۷ استفاده کردیم. سپس از لایه‌های فازی که تعریف کرده بودیم، کمک گرفتیم و ابتدا خروجی که داشتیم را با لایه ۸ نورونی فازی نموده و در ادامه دوباره از لایه‌های متراکم با ۸ و ۱۶ نورون استفاده کردیم. در آخر خروجی را با کمک لایه غیرفازی کننده با دو نورون به دست آوردیم.

۲-۳- معیارهای ارزیابی

عملکرد این شبکه‌ها روی داده‌ها بررسی و نتایج با هم مقایسه شدند و در نهایت شبکه بهینه تعیین شد. به منظور

شبکه‌های کانوولوشنی استفاده شده شامل سه لایه کانوولوشنی با فیلتر سائز یکسان و کرنل سائزهای متفاوت بودند، به این صورت که لایه اول یک لایه کانوولوشنی با فیلتر سائز ۲۰۰ و کرنل سائز ۲ دارد. در لایه دوم شبکه نیز فیلتر سائز همان ۲۰۰ ولی کرنل سائز را ۳ در نظر گرفتیم و لایه سوم نیز با همان فیلتر سائز، و کرنل سائز را ۴ در نظر گرفتیم. در هر سه لایه از تابع فعال‌ساز relu و همین‌طور از $\text{BatchNormalization}$ نیز استفاده شد. همچنین از GlobalMaxPooling در ادامه استفاده شد و سه لایه قبلی با هم ادغام شدند. سپس از یک لایه متراکم^۲ ۳۰ نورونی و در ادامه برای کلاس‌بندی قطبیت منفی و مثبت از یک لایه متراکم با دو نورون برای خروجی استفاده کردیم. در آخر از تابع فعال‌ساز Softmax استفاده شد. ابعاد ورودی ۵۰٪ است که در ادامه و با عبور از لایه embedding به ۶۴٪*۱ تغییر می‌کند.

لازم به ذکر است که برای جلوگیری از بیش‌برازش^۴ در شبکه از SpatialDropout هم استفاده شد و برابر ۰.۲ در نظر گرفته شده است. در بخش نتایج، از این معماری با عنوان CNN1 یاد می‌شود. معماری CNN1 بهترین معماری بود که به آن رسیدیم زیرا بهترین صحت و دقت را توانستیم با این معماری به دست آوریم. یکی از مهم‌ترین دلایل عملکرد مناسب این شبکه وجود سه لایه کانوولوشنی با تعداد فیلتر یکسان است زیرا با این روش ارتباطی که بین داده‌ها وجود دارد بهتر درک می‌شود. همان‌طور که می‌دانیم درک ارتباط داده‌های سری زمانی مانند متن‌ها برای کلاس‌بندی آن‌ها بسیار اهمیت دارد. این شبکه این امکان را ایجاد می‌کند تا داده‌ها به صورت بهینه و با یک مدل سبک و به صرفه آموزش داده شوند. همچنین معماری منحصر به فرد این شبکه عمیق باعث شد تا حدودی بتوانیم کمبود داده و بالانس نبودن آن را جبران نماییم و به صحت بهتری در مقایسه با دیگر شبکه‌های استفاده شده برسیم.

در ادامه از یک معماری دیگر شبکه کانوولوشنی نیز استفاده کردیم که از سه لایه کانوولوشنی تشکیل شده است. بر خلاف معماری قبلی، در این معماری سائز فیلترها را نیز تغییر دادیم. فیلتر سائزهای لایه اول تا سوم را به ترتیب ۳۲، ۱۲۸ و ۱۹۲ در نظر گرفتیم (لازم به ذکر است که

⁵ Fuzzifier

⁶ De fuzzifier

⁷ Sigmoid

¹ Filter size

² Kernel size

³ Dense

⁴ Overfitting

همچنین نتایج جدول ۱ نشان می‌دهد که اضافه کردن داده‌ها با روش شبه‌برچسب‌زدن به داده‌های واقعی، بهتر از روش بیش‌نمونه‌برداری عمل می‌کند. زیرا در شبکه‌هایی مانند CNN2 نیز مشخص است که صحت روی داده‌های اولیه و شبه‌برچسب‌زدن بالاتر از صحت روی داده‌های اولیه و بیش‌نمونه‌برداری است. البته تعداد داده بیشتر می‌تواند به بهبود عملکرد شبکه‌های عمیق کمک کند.

جدول ۱- مقایسه صحت بدست آمده با استفاده از شبکه‌های عمیق متفاوت.

صحت برای داده‌های اولیه و روش شبه-برچسب‌زدن	صحت برای داده‌های اولیه و روش بیش-نمونه‌برداری	صحت برای داده‌های اولیه	معماری شبکه
۷۲.۲۹	۷۱.۴۲	۷۰.۹۹	CNN1
۷۰.۵۶	۷۰.۲۲	۶۹.۲۳	CNN2
۶۲.۵۳	۶۰.۷۳	۵۹.۶۶	LSTM
۵۰.۰۰	۴۷.۰۴	۴۹.۵۳	FUZZY-LSTM

ماتریس درهم‌ریختگی مربوط به شبکه کانولوشنی CNN1 در شکل (۲) نشان داده شده است. همان‌طور که از این شکل مشخص است شبکه بهینه (CNN1) توانسته است ۴۹ درصد داده‌ها را به درستی در کلاس مثبت پیش‌بینی کند، همچنین ۵۱ درصد داده‌ها را به غلط در کلاس مثبت پیش‌بینی کرده است. این تناقض به این دلیل پیش آمده است که در مجموعه داده موجود، تعداد داده‌های متعلق به کلاس منفی ۱۷۱۱ رکورد است که نسبت به کلاس مثبت با تعداد ۲۳۶۷ رکورد، کمتر است. شبکه توانسته است ۸۴ درصد را به درستی در کلاس منفی پیش‌بینی کند و تنها ۱۶ درصد از کلاس منفی به اشتباه پیش‌بینی شده است.

مقایسه صحت شبکه CNN1 روی داده‌های ارزیابی و آموزش نیز در شکل (۳) آورده شده است. همان‌طور که در این شکل دیده می‌شود صحت روی داده‌های آموزش^۶ حدوداً ۹۸ درصد است ولی روی داده‌های ارزیابی به ۷۸ درصد، در دوره^۷ ۳۰ رسیده است و این میزان صحت، بالاتر رفتن دوره‌ها، تغییر محسوسی روی داده‌های ارزیابی

مقایسه عملکرد شبکه‌ها و مشخص کردن بهینه‌ترین آن‌ها از معیارهای ارزیابی شامل صحت^۱، دقت^۲، بازیابی^۳ و امتیاز اف-۱^۴ استفاده شد که با بررسی آن‌ها می‌توانیم به درک بهتری از عملکرد شبکه روی هر کلاس برسیم. فرمول‌های این پارامترهای ارزیابی به صورت زیر می‌باشند:

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

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

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

$$f1 = 2 \cdot \frac{PRECISION \cdot RECALL}{PRECISION + RECALL} \quad (۴)$$

در اینجا TP مخفف true positive، FP مخفف false positive، FN مخفف false negative و FP همان false positive است که در ماتریس درهم‌ریختگی^۵ می‌توان هر یک از این مقادیر را مشاهده کرد.

۳-نتایج

در این بخش نتایج چهار معماری CNN1، CNN2، LSTM و Fuzzy-LSTM روی سه حالت از مجموعه داده بررسی و مقایسه می‌شوند (جدول ۱). هرکدام از شبکه‌ها را روی داده اصلی، داده اصلی به همراه داده بیش‌نمونه‌برداری و داده اصلی به همراه داده‌های شبه‌برچسب‌زنی به صورت جداگانه اعمال کردیم.

معماری CNN1 با فیلتر سائزهای یکسان و کرنل سائزهای متفاوت، روی داده‌های اصلی به علاوه داده‌های اضافه شده با شبه‌برچسب‌زدن بهترین نتیجه ممکن برای کلاس‌بندی قطبیت باینری را به ما می‌دهد. صحت به دست آمده با این شبکه ۷۲.۲۹ است. همچنین صحت به دست آمده با شبکه‌های دیگر نیز در جدول ۱ نمایش داده شده است که کمتر از این مقدار است. همان‌طور که گفته شد بهترین معماری CNN1 است زیرا در مقایسه با دیگر شبکه‌های استفاده شده نه تنها با شبه‌برچسب‌زدن بلکه روی داده اولیه و داده اولیه به همراه بیش‌نمونه‌برداری نیز نتایج بهتری در مقایسه با دیگر شبکه‌ها ارائه می‌دهد.

⁵ Confusion Matrix

⁶ Train

⁷ Epoch

¹ Accuracy

² Precision

³ Recall

⁴ F1-score

۳-۱- مقایسه با کارهای پیشین

باتوجه به اینکه شبکه کانولوشنی استفاده شده در مطالعه [۱۱] بر روی زبان فارسی ارایه شده است، در این بخش نتایج کلاس‌بندی قطبیت داده‌های مربوط به کرونا با استفاده از شبکه پیشنهادی در مطالعه حاضر و شبکه استفاده شده در مطالعه [۱۱] با هم مقایسه می‌شود.

علیرغم اینکه در پژوهش [۱۱] از شبکه کانولوشنی استفاده شده است اما جزئیات شبکه کانولوشنی پیشنهادی ما از نظر تعداد و اندازه فیلترها، تعداد نورون‌ها، تابع فعال‌ساز و همچنین به کارگیری Batch Normalization و Dropout از شبکه استفاده شده در پژوهش [۱۱] متمایز است. شبکه پژوهش [۱۱] شامل سه لایه کانولوشن است که فیلتر سایز هر سه لایه ۶۴ و کرنل سایزها نیز به ترتیب ۴، ۸ و ۱۶ می‌باشند. تنها در لایه آخر از Dropout استفاده شده و مقدار آن نیز ۰.۱ بوده است، تعداد نورون‌های لایه متراکم ۵۰۰ می‌باشد و تابع فعال‌ساز سیگموئید به کار گرفته شده است. درحالی‌که در شبکه پیشنهادی ما فیلتر سایز ۲۰۰ و کرنل سایزها به ترتیب ۲، ۳ و ۴ در نظر گرفته شده‌اند، همچنین مقدار Dropout در هر لایه ۰.۲، و تعداد نورون‌های لایه متراکم ۳۰ در نظر گرفته شده‌اند، و تابع فعال‌ساز Softmax استفاده شده است.


صحت بدست آمده با استفاده از شبکه معرفی شده در مطالعه [۱۱] برای کلاس‌بندی داده‌های زبان فارسی در بیماری کرونا، ۶۳ درصد می‌باشد که نسبت به صحت حاصل از شبکه پیشنهادی ما کمتر می‌باشد.

۳-۲- بحث


یکی از کاربردهای مهم تحلیل احساسات هنگام رویارویی جوامع با بحران‌هایی مانند کرونا می‌باشد. در این پژوهش پیام‌های به اشتراک گذاشته شده به زبان فارسی در دوران کرونا با استفاده از روش‌های با ناظر بررسی شده‌اند. یکی از این روش‌ها یادگیری عمیق است که برای تحلیل احساسات در حوزه‌های مالی بسیار استفاده شده است [۴۹].

در این پژوهش به کلاس‌بندی پیام‌های استخراج شده از شبکه‌های اجتماعی با محوریت قطبیت این پیام‌ها با استفاده از یادگیری عمیق پرداختیم. شبکه‌های یادگیری عمیق مانند شبکه‌های کانولوشنی و بازگشتی می‌توانند در وقت و هزینه صرفه‌جویی کنند، به خصوص برای داده‌های متنی که استخراج ویژگی به صورت دستی اغلب سخت و

و آموزش نداشته و تقریباً پایدار مانده است.



شکل ۲- ماتریس درهم‌ریختگی حاصل از کلاس‌بندی با استفاده از CNN1.



شکل ۳- مقایسه صحت در داده‌های آموزش و ارزیابی.

علاوه بر صحت، پارامترهای دیگری مانند دقت، بازیابی و امتیاز اف-۱ را نیز برای همان شبکه بهینه محاسبه کردیم تا عملکرد دقیق‌تر شبکه را روی داده‌ها بررسی کنیم. نتایج در جدول ۲ آورده شده است، همان‌طور که در جدول دیده می‌شود مقادیر این پارامترها برای کلاس منفی بیشتر از کلاس مثبت است، زیرا تعداد داده‌ها در این کلاس بیشتر است.

جدول ۲- مقایسه پارامترهای دقت، بازیابی و امتیاز اف-۱ شبکه بهینه CNN1 برای هر دو کلاس مثبت و منفی.

کلاس	دقت	بازیابی	امتیاز اف-۱
مثبت	۰.۴۹۳۵	۰.۶۰۳۲	۰.۵۴۲۹
منفی	۰.۸۳۷۷	۰.۷۶۷۹	۰.۸۰۱۲

داده‌های مربوط به کرونا در زبان فارسی عملکرد بهتری دارد.

رویکرد پیشنهادی از پارامترهای صحت، دقت، بازیابی و امتیاز اف-۱ برای بررسی عملکرد شبکه‌ها و مقایسه آنها استفاده کرده است. با بررسی و مقایسه پارامترهای ذکر شده در معماری‌های متفاوت شبکه‌های عصبی عمیق، معماری شبکه CNN1 انتخاب شد که با توجه محدودیت‌های موجود مانند کمبود داده‌ها و بالانس نبودن توزیع کلاس‌ها، طراحی منحصربه‌فرد الگوریتم پیشنهادی توانست تا حدودی بر این مشکلات غلبه کند و نتایج نسبتاً قابل قبولی ارائه دهد. همچنین برای برطرف کردن محدودیت کمبود داده از روش شبه نظارتی شبه‌برچسب‌زدن به منظور برچسب‌زنی تعداد بیشتری از داده‌ها استفاده کردیم، و همین طور تلاش کردیم تا با روش بیش‌نمونه‌برداری تا حدی توازن را بین کلاس مثبت و منفی برقرار کنیم. ترکیب داده اصلی با داده‌های اضافه شده با روش شبه نظارتی توانست نتایج را بهبود بخشد. این نشان می‌دهد که تعداد داده واقعی بیشتر در بهبود شبکه‌های یادگیری عمیق موثر خواهد بود. به همین منظور در کارهای پیش‌رو نیز می‌توانیم عملکرد مدل پیشنهادی در حضور داده‌های بیشتر و حل کردن مشکل کمبود داده را بررسی کنیم. همچنین می‌توانیم این پیام‌ها را علاوه بر قطبیت آن‌ها از جنبه‌های دیگری مانند غم، شادی، ترس، مذهبی، سیاسی، علمی و ... بررسی نماییم.

این تحقیق به قسمت کوچکی از نظرات مردم در دوران همه‌گیری پرداخته است و با استفاده از روش‌های نظارتی و شبه نظارتی رویکرد مردم ایران را نسبت به بیماری غالباً مثبت ارزیابی کرده است که این موضوع می‌تواند چند دلیل داشته باشد، اول این موضوع مطرح است که مردم این بیماری را دست کم گرفته بودند و به این دلیل رویکردشان نسبت به آن مثبت بوده است و دوم اینکه مردم ایران عموماً با موضوعات مختلف با رویکرد شوخی طنز برخورد می‌کنند. همچنین این دستاورد نشان می‌دهد که مردم ایران علاوه بر اینکه در طول پاندمی احساسات منفی را تجربه کرده‌اند، احساسات مثبتی مانند همبستگی، قردانی و ... را نیز تجربه کرده‌اند. اما در آینده می‌توان تعداد داده بیشتری را مورد بررسی قرار داد و نتایج این تحقیق را تعمیم داد. در کارهای آتی به دنبال بررسی عمیق‌تر روش‌های برچسب‌گذاری برای تولید داده بیشتر و نیز استفاده از روش‌های

زمان‌بر است. به همین دلیل یادگیری عمیق گزینه مناسب‌تری نسبت به روش‌های استخراج ویژگی دستی می‌باشد. زیرا می‌تواند ویژگی‌های زیادی را به صورت خودکار از داده‌ها استخراج کند.

بررسی قطبیت یک رویکرد کلی برای تحلیل احساسات محسوب می‌شود و می‌تواند احساسات مختلفی را شامل شود. در پژوهش حاضر، به دلیل ماهیت چالش برانگیز تحلیل احساسات، بررسی قطبیت روش مناسبی برای تحلیل محتوای پیام‌ها می‌باشد. بنابراین هم روش پیشنهادی و هم محتوای پیام‌ها (کرونا) باعث تمایز این پژوهش می‌شود. مطالعاتی با استفاده از یادگیری عمیق در زبان مختلف مانند انگلیسی و چینی به تحلیل احساسات در زمان کرونا پرداخته‌اند در حالیکه این رویکرد در زبان فارسی انجام نشده است. البته در مطالعات پیشین [۱۱] قطبیت پیام‌ها به زبان فارسی در حوزه‌های مربوط به اقتصاد بررسی شده است. به عنوان مثال در پژوهشی نظرات مردم در مورد فروش کالاها در شرکت دیجی کالا از نظر قطبیت بررسی شد، اما در مورد بیماری کرونا پژوهشی به این رویکرد در زبان فارسی نپرداخته است و استفاده از این رویکرد روی داده‌های مربوط به کرونا می‌تواند این خلا را پر کند. پیش‌پردازش داده‌های خام مورد استفاده در این پژوهش نیز چالش بیشتری برای کلاس‌بندی ایجاد کرد. بنابراین علاوه بر روش استفاده شده هدف پژوهش نیز باعث تمایز این کار می‌شود. برای تحلیل قطبیت پیام‌های حوزه کرونا، در الگوریتم پیشنهادی از شبکه کانولوشنی استفاده شده است که تعداد فیلترها و اندازه آن‌ها در این کار از پژوهش پیشین [۱۱] متمایز است. همچنین در پژوهش حاضر برای سرعت بخشیدن و دستیابی به صحت بالاتر، در هر لایه از Batch Normalization و Dropout استفاده شد و نیز مقادیر Dropout تغییر داده شد. تفاوت دیگر شبکه پیشنهادی نسبت به مطالعه پیشین [۱۱]، تغییر در تابع فعال‌سازی و همچنین تعداد نورون‌های لایه مترام می‌باشد. نتایج نشان می‌دهد شبکه پیشنهادی عملکرد بهتری برای کلاس‌بندی داده‌های فارسی مربوط به بیماری کرونا داشته است. شبکه پیشنهادی در مطالعه حاضر توانسته است داده‌ها را با صحت ۷۲.۲۹ کلاس‌بندی کند در حالیکه شبکه استفاده شده در مطالعه پیشین برای کلاس‌بندی داده‌های مربوط به کرونا صحت ۶۳ درصد را نشان می‌دهد. بنابراین، شبکه پیشنهادی برای کلاس‌های

جمع آوری شده است، می‌تواند دولت‌ها را به درک بهتری از رویکرد جمعیت کشورشان نسبت به این بیماری برساند. به علاوه دولت‌ها می‌توانند با استفاده از نتایج این تحقیق و تحقیقات پیش‌رو در ابعاد وسیع‌تر، عملکردشان را براساس نظر مردم و تاثیرات مثبت و منفی که این بیماری بر افکار مردم داشته است را بسنجند و به درک بهتری از الگوی رفتاری مردم برسند.

در این مقاله پیام‌های به اشتراک گذاشته شده به زبان فارسی در شبکه‌های اجتماعی و در بحران کرونا، براساس قطبیت مثبت و منفی پیام‌ها کلاس‌بندی شدند. برای کلاس‌بندی شبکه‌های عمیق متفاوتی شامل شبکه‌های CNN، LSTM و Fuzzy-LSTM استفاده شد که بهترین نتیجه با استفاده از شبکه عمیق کانولوشنی با سه لایه بدست آمد.

شبه نظارتی برای آموزش مدل تحلیل احساس بر روی داده‌های مربوط به کرونا هستیم. همچنین می‌توان برای آموزش داده‌ها علاوه بر شبکه‌های عمیق کانولوشنی از تلفیق شبکه‌های بازگشتی مانند حافظه بلند مدت کوتاه و شبکه‌های کانولوشن استفاده کرد و نتایج را بهبود بخشید زیرا شبکه‌های کانولوشنی در استخراج ویژگی خیلی خوب عمل می‌کنند و شبکه‌های حافظه بلند مدت کوتاه در درک روابط بین جملات و حفظ اطلاعات عملکرد مطلوبی دارند، به همین خاطر تلفیق این دو شبکه در رویکردهای آتی می‌تواند باعث بهبود پارامترهای ارزیابی شود.

۴- نتیجه گیری

امروزه شبکه‌های اجتماعی فضایی را ایجاد کرده است که مردم آزادانه بتوانند در مورد احساساتشان اظهار نظر کنند. پس بررسی قطبیت این پیام‌ها که در دوران پاندمی

مراجع

- [1] L.-C. Chen, C.-M. Lee, and M.-Y. Chen, "Exploration of social media for sentiment analysis using deep learning," *Soft Computing*, Vol. 24, NO. 11, 2020, pp. 8187-8197.
- [2] O. Ahlgren, "Research on sentiment analysis: the first decade." 2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW), 2016, pp. 890-899.
- [3] D. Q. Nguyen, D. Q. Nguyen, T. Vu et al., "Sentiment classification on polarity reviews: an empirical study using rating-based features," 2014.
- [4] S. Shumaly, M. Yazdinejad, and Y. Guo, "Persian sentiment analysis of an online store independent of pre-processing using convolutional neural network with fastText embeddings," *PeerJ Computer Science*, Vol. 7, 2021, pp. e422.
- [5] S. Wu, Y. Liu, J. Wang et al., "Sentiment analysis method based on Kmeans and online transfer learning," *Comput. Mater. Contin.*, Vol. 60, 2019, pp. 1207-1222.
- [6] D. Dangi, D. K. Dixit, and A. Bhagat, "Sentiment analysis of COVID-19 social media data through machine learning," *Multimedia Tools and Applications*, vol. 81, no. 29, 2022, pp. 42261-42283.
- [7] L. Nemes, and A. Kiss, "Social media sentiment analysis based on COVID-19," *Journal of Information and Telecommunication*, Vol. 5, NO. 1, 2021, pp. 1-15.
- [8] M. Arbane, R. Benlamri, Y. Brik et al., "Social media-based COVID-19 sentiment classification model using Bi-LSTM," *Expert Systems with Applications*, Vol. 212, 2023, pp. 118710.
- [9] D. Xie, L. Zhang, and L. Bai, "Deep learning in visual computing and signal processing," *Applied Computational Intelligence and Soft Computing*, Vol. 2017, 2017.
- [10] L. Zhang, S. Wang, and B. Liu, "Deep learning for sentiment analysis: A survey," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Vol. 8, NO. 4, 2018, pp. e1253.
- [11] J. P. R. Sharami, Sarabestani, P. A., & Mirroshandel, S. A. , "DeepSentiPers: Novel Deep Learning Models Trained Over Proposed Augmented Persian Sentiment Corpus.," *arXiv preprint 2020*, arXiv:2004.05328.
- [12] ف. شمیم و د. سینا، "تحلیل احساسات در شبکه‌های اجتماعی با پردازش زبان طبیعی و رویکرد یادگیری عمیق"، در ششمین کنفرانس ملی پژوهش‌های کاربردی در مهندسی کامپیوتر و فناوری اطلاعات، تهران، ایران، ۲۴ بهمن، ۱۳۹۸.
- [13] H. Liang, X. Sun, Y. Sun et al., "Text feature extraction based on deep learning: a review," *EURASIP journal on wireless communications and networking*, Vol. 2017, NO. 1, 2017, pp. 1-12.

- [14] D. W. Otter, J. R. Medina, and J. K. Kalita, "A survey of the usages of deep learning for natural language processing," *IEEE transactions on neural networks and learning systems*, Vol. 32, NO. 2, 2020, pp. 604-624.
- [15] Y. Chen, "Convolutional neural network for sentence classification," University of Waterloo, 2015.
- [16] W. K. Sari, D. P. Rini, and R. F. Malik, "Text classification using long short-term memory." 2019 International Conference on Electrical Engineering and Computer Science (ICECOS), 2019, pp. 150-155.
- [17] R. Wang, Z. Li, J. Cao et al., "Convolutional recurrent neural networks for text classification." 2019 International Joint Conference on Neural Networks (IJCNN), 2019, pp. 1-6.
- [18] Z. Shaheen, G. Wohlgenannt, and E. Filtz, "Large scale legal text classification using transformer models," arXiv preprint, 2020, arXiv:2010.12871.
- [19] Z. Li, F. Liu, W. Yang et al., "A survey of convolutional neural networks: analysis, applications, and prospects," *IEEE transactions on neural networks and learning systems*, 2021.
- [20] P. Sharma, and A. Singh, "Era of deep neural networks: A review." 2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT), 2017, pp. 1-5.
- [21] J. Xu, D. Chen, X. Qiu et al., "Cached long short-term memory neural networks for document-level sentiment classification," arXiv preprint, 2016, arXiv:1610.04989.
- [22] K. Uma, and K. Meenakshisundaram, "Optimization based fuzzy deep learning classification for sentiment analysis," *Int J Sci Technol Res*, Vol. 9, NO. 3, 2020, pp. 7.
- [23] B. Mohamed, H. Haytam, and F. Abdelhadi, "Applying Fuzzy Logic and Neural Network in Sentiment Analysis for Fake News Detection: Case of Covid-19," *Combating Fake News with Computational Intelligence Techniques*, 2022, pp. 387-400: Springer.
- [24] E. Ferri, and G. Langholz, "Neuro-Fuzzy Approach to Natural Language Understanding and Processing," *Intelligent systems and interfaces*, pp. 261-280: Springer, 2000.
- [25] X. Yu, C. Zhong, D. Li et al., "Sentiment analysis for news and social media in COVID-19." *Proceedings of the 6th ACM SIGSPATIAL International Workshop on Emergency Management using GIS*, 2020, pp. 1-4.
- [26] N. Chintalapudi, G. Battineni, and F. Amenta, "Sentimental analysis of COVID-19 tweets using deep learning models," *Infectious Disease Reports*, Vol. 13, NO. 2, 2021, pp. 329-339.
- [27] T. Wang, K. Lu, K. P. Chow et al., "COVID-19 sensing: negative sentiment analysis on social media in China via BERT model," *Ieee Access*, Vol. 8, 2020, pp. 138162-138169.
- [28] F. Amiri, S. Abbasi, and M. Babaie Mohamadeh, "Clustering Methods to Analyze Social Media Posts during Coronavirus Pandemic in Iran," *Journal of AI and Data Mining*, 2022.
- [29] F. Kaveh-Yazdy, and S. Zarifzadeh, "Track Iran's national COVID-19 response committee's major concerns using two-stage unsupervised topic modeling," *International journal of medical informatics*, Vol. 145, 2021, pp. 104309.
- [30] P. Hosseini, P. Hosseini, and D. A. Broniatowski, "Content analysis of Persian/Farsi Tweets during COVID-19 pandemic in Iran using NLP," arXiv preprint, 2020, arXiv:2005.08400.
- [31] Z. B. Nezhad, and M. A. Deihimi, "Twitter sentiment analysis from Iran about COVID 19 vaccine," *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, Vol. 16, NO. 1, 2022, pp. 102367.
- [32] D.-H. Lee, "Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks." *Workshop on challenges in representation learning, ICML, 2013*, Vol. 3, NO. 2, p. 896.
- [33] F. Rodríguez-Torres, J. F. Martínez-Trinidad, and J. A. Carrasco-Ochoa, "An Oversampling Method for Class Imbalance Problems on Large Datasets," *Applied Sciences*, Vol. 12, NO. 7, 2022, pp. 3424.
- [34] S. Jain, "Introduction to pseudo-labelling: A semi-supervised learning technique," URL= <https://www.analyticsvidhya.com/blog/2017/09/pseudo-labellingsemi-supervised-learning-technique>, 2017.
- [35] P. Cascante-Bonilla, F. Tan, Y. Qi et al., "Curriculum labeling: Revisiting pseudo-labeling for semi-supervised learning." *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 35, NO. 8, 2021, pp. 6912-6920.
- [36] R. Mohammed, J. Rawashdeh, and M. Abdullah, "Machine learning with oversampling and undersampling techniques: overview study and experimental results." 2020 11th international conference on information and communication systems (ICICS), 2020, pp. 243-248.

- [37] A. Moreo, A. Esuli, and F. Sebastiani, "Distributional random oversampling for imbalanced text classification." Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval, 2016, pp. 805-808.
- [38] J. Kacprzyk, "Lecture notes in networks and systems," Springer, 2019.
- [39] N. Ketkar, "Introduction to keras," Deep learning with Python, pp. 97-111: Springer, 2017.
- [40] S.-H. Lee, K.-W. Huang, and C.-S. Yang, "TBAS: Token-based authorization service architecture in Internet of things scenarios," International Journal of Distributed Sensor Networks, Vol. 13, NO. 7, 2017, pp. 1550147717718496.
- [41] H. Zhou, "Research of Text Classification Based on TF-IDF and CNN-LSTM." Journal of Physics: Conference Series, 2022, Vol. 2171, NO. 1, pp. 012021.
- [42] Y. Luan, and S. Lin, "Research on text classification based on CNN and LSTM." 2019 IEEE international conference on artificial intelligence and computer applications (ICAICA), 2019, pp. 352-355.
- [43] W. Yin, K. Kann, M. Yu et al., "Comparative study of CNN and RNN for natural language processing," arXiv preprint, 2017, arXiv:1702.01923.
- [44] K. Yoon, "Convolutional Neural Networks for Sentence Classification [OL]," arXiv Preprint, 2014.
- [45] F. Ali, S. El-Sappagh, and D. Kwak, "Fuzzy ontology and LSTM-based text mining: a transportation network monitoring system for assisting travel," Sensors, Vol. 19, NO. 2, 2019, pp. 234.
- [46] A. BERRAJAA, "Natural Language Processing for the Analysis Sentiment using a LSTM Model," International Journal of Advanced Computer Science and Applications, Vol. 13, NO. 5, 2022.
- [47] K. FUKUSHIMA, "Neocognitron: Deep convolutional neural network," Cognitive science, Vol. 29, NO. 1, 2022, pp. 14-23.
- [48] Y. Yu, X. Si, C. Hu et al., "A review of recurrent neural networks: LSTM cells and network architectures," Neural computation, Vol. 31, NO. 7, 2019, pp. 1235-1270.
- [49] S. Sohangir, D. Wang, A. Pomeranets et al., "Big Data: Deep Learning for financial sentiment analysis," Journal of Big Data, Vol. 5, NO. 1, 2018, pp. 1-25.