



دانشگاه کاشان  
University of Kashan

مجله محاسبات نرم

## SOFT COMPUTING JOURNAL

تارنمای مجله: [sci.kashanu.ac.ir](http://sci.kashanu.ac.ir)



### ارزیابی روش های یادگیری کلاسیک و یادگیری عمیق در تجزیه و تحلیل احساسات داده های تلگرام

فارسی

فاطمه زارع مهرجردی<sup>۱</sup>، دانشجوی دکتری، مهدی یزدیان دهکردی<sup>۱\*</sup>، استادیار، علی محمد لطیف<sup>۱</sup>، دانشیار  
<sup>۱</sup> دانشکده مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران.

#### چکیده

#### اطلاعات مقاله

#### تاریخچه مقاله:

دریافت ۱۱ تیر ماه ۱۴۰۱

پذیرش ۲۵ آذر ماه ۱۴۰۱

#### کلمات کلیدی:

تجزیه و تحلیل احساسات

پیام های تلگرام

یادگیری ماشین

یادگیری عمیق

امروزه اینترنت و به خصوص شبکه های اجتماعی مانند توئیتر، فیس بوک و تلگرام به بستری برای تبادل ایده ها و به اشتراک گذاری نظرات کاربران تبدیل شده است. تجزیه و تحلیل احساسات بر اساس نظرات کاربران در این شبکه ها می تواند کمک شایانی در توضیح و پیش بینی پدیده های اجتماعی و همچنین یافتن محصولات یا خدمات مناسب برای افراد، شرکت ها و سازمان ها نماید. تاکنون پژوهش های زیادی بر روی داده های شبکه های اجتماعی به زبان انگلیسی انجام شده است؛ اما برای زبان فارسی پژوهش های محدودی انجام شده است. در این مقاله یک سیستم تجزیه و تحلیل احساسات بر روی داده های تلگرام فارسی پیشنهاد شده است. برای این منظور، چند روش استخراج ویژگی شامل بردار رخداد، فراوانی اصطلاح-معکوس فراوانی سند و ماتریس تعبیه کلمات جهت بازنمایی داده های متنی به عددی بررسی شده است. سپس جهت طبقه بندی داده ها روش های مختلف یادگیری ماشین کلاسیک شامل ماشین بردار پشتیبان، درخت تصمیم، K نزدیک ترین همسایه، بیز ساده و رگرسیون منطقی، تلفیق روش های کلاسیک و همچنین روش های یادگیری عمیق شامل شبکه عصبی عمیق، شبکه عصبی پیچشی و شبکه های حافظه طولانی کوتاه مدت یک طرفه و دوطرفه بررسی شده است. در نهایت ارزیابی و تحلیل نتایج بر روی داده های جمع آوری شده از تلگرام فارسی نشان می دهد که بهترین کارایی توسط روش استخراج ویژگی ماتریس تعبیه کلمات به همراه شبکه حافظه طولانی کوتاه مدت دوطرفه با دقت ۹۰/۶۷، صحت ۹۰/۰۱، فراخوان ۸۹/۵۴ و معیار F، ۸۹/۷۷ درصد به دست آمده است.

© ۱۴۰۱ نویسنده گان. مقاله با دسترسی آزاد تحت مجوز CC-BY (cc) BY

#### ۱. مقدمه

به روز افزایش یافته است. کاربران نظرات و تجربیات خود را در مورد یک محصول، سیاست و یا یک رویداد خاص به اشتراک می گذارند. لذا دانش موجود در متن نظرات آنها یکی از موضوعات مطالعاتی مهم محسوب می شود [۱]-[۳].

با رشد سریع شبکه های اجتماعی و وبلاگ ها سرعت استفاده از قابلیت های این رسانه های اجتماعی توسط کاربران برخط روز

\* نوع مقاله: پژوهشی

# نویسنده مسئول

پست (های) الکترونیک: zarefateme@stu.yazd.ac.ir (زارع مهرجردی)

yazdian@yazd.ac.ir (یزدیان دهکردی)

alatif@yazd.ac.ir (لطیف)

نحوه ارجاع به مقاله: زارع مهرجردی، فاطمه، یزدیان دهکردی، مهدی، لطیف، علی محمد، «ارزیابی روش های یادگیری کلاسیک و یادگیری عمیق در تجزیه و تحلیل احساسات داده های تلگرام فارسی»، مجله محاسبات نرم، جلد ۱۱، شماره ۱، ص ۱۰۵۸۸، بهار و تابستان ۱۴۰۱.

هدف آن استخراج و جمع‌بندی نظرات و احساسات مردم در سطح کلان در مورد جنبه خاصی از یک موجودیت است [۱۲]. هرچند پژوهش‌های متعددی برای تجزیه و تحلیل احساسات جملات انگلیسی انجام شده است، اما در حوزه فارسی پژوهش قابل توجهی انجام نشده است. این پژوهش به تعیین احساسات با قطبیت مثبت و منفی در سطح جملات فارسی در شبکه اجتماعی تلگرام می‌پردازد.

یکی از رویکردهای سنتی تجزیه و تحلیل احساسات، روش‌های مبتنی بر دانش یا لغت‌نامه می‌باشند [۱۳]. در این روش‌ها احساسات توسط یک شخص خبره در یک حوزه بخصوص و با تعیین کلماتی خاص مشخص می‌شود. کلماتی مانند «بد»، «زشت» و «ترسناک» دارای احساس منفی و کلماتی مانند «خوب» یا «زیبا» دارای احساس مثبت هستند. شخص خبره واژه‌نامه‌ای از کلمات احساسی را ایجاد می‌کند و با کلمات مترادف و متضاد آن را گسترش می‌دهد [۱۴]، [۱۵]. امتیاز احساسات یک سند یا جمله بر اساس امتیاز کلمات موجود در آنها تعیین می‌شود. روش‌های مبتنی بر دانش نیازی به داده‌های آموزشی ندارند اما در این روش‌ها تجزیه و تحلیل احساسات به‌شدت وابسته به حوزه مورد بررسی و وابسته به شخص خبره است [۱۶]-[۱۸].

رویکرد دیگر تجزیه و تحلیل احساسات روش‌های یادگیری ماشین هستند که توانایی مدل‌سازی و استخراج خودکار دانش بر اساس داده‌های آموزشی را دارند. این روش‌ها را می‌توان به دو دسته یادگیری بدون نظارت و با نظارت تقسیم‌بندی کرد. در روش‌های بدون نظارت، داده‌های آموزشی بدون برچسب بوده و الگوریتم یادگیری سعی می‌کند داده‌های شبیه به یکدیگر را در خوشه‌های مجزا قرار دهد. در روش‌های با نظارت داده‌های آموزشی دارای برچسب قطبیت از نظر مثبت و منفی بوده و مدل طبقه‌بندی بر اساس این داده‌ها آموزش داده می‌شود. این مدل برچسب داده‌های ورودی جدید را پیش‌بینی می‌کند. روش‌های با نظارت با پذیرفتن هزینه برچسب‌گذاری داده‌ها، اغلب کارایی بهتری نسبت به روش‌های بدون نظارت دارند [۱۹]. در این پژوهش تجزیه و تحلیل پیام‌های فارسی تلگرام بر اساس

تجزیه و تحلیل احساسات به این مهم می‌پردازد [۱]. تجزیه و تحلیل احساسات یا کاوش افکار، احساسات و نگرش افراد در رابطه با مواردی مانند محصولات، خدمات، چالش‌ها، رویدادها، موضوعات و ویژگی‌های آنها است. بدین ترتیب، تجزیه و تحلیل احساسات می‌تواند به جستجوی خلق و خوی مردم در مورد یک موضوع خاص و بکارگیری آن در عمل کمک کند. همچنین می‌توان از این نوع دانش به منظور درک، توضیح و پیش‌بینی پدیده‌های اجتماعی استفاده کرد. در حوزه کسب و کار تجزیه و تحلیل احساسات نقشی اساسی در بهبود استراتژی و کسب بینش در مورد بازخورد مشتریان درباره محصولات دارد، چون در فرهنگ تجارت مشتری مداری امروز، درک مشتری به طور فزاینده‌ای مهم است [۱]-[۵].

تلگرام یکی از پرستفاده‌ترین شبکه‌های اجتماعی در بین کاربران فارسی زبان است که با رد و بدل کردن روزانه حدود ۱۵ میلیارد پیام از پرطرفدارترین شبکه‌های اجتماعی در ایران محسوب می‌شود [۶]. مردم ایران در محیط تلگرام بیش از ۱۷۰ هزار شبکه تلگرامی راه انداخته‌اند، که در این میان ۱۱ هزار کانال بیش از ۵۰۰۰ نفر عضو دارد. هر کاربر ایرانی به‌طور میانگین در ۱۰ کانال عضویت دارد و روزانه بیش از ۱۰۰ مطلب را از تلگرام مطالعه می‌کند [۶]. بنابراین تجزیه و تحلیل احساسات در این شبکه اجتماعی نیز از اهمیت بسزایی برخوردار است. یکی از شناخته شده‌ترین کارها در تجزیه و تحلیل احساسات، طبقه‌بندی احساسات بر اساس قطبیت آنها است. به‌طور سنتی قطبیت به دو صورت مثبت یا منفی طبقه‌بندی می‌شود [۷]، [۸]. برخی از مطالعات شامل قطبیت دیگری به نام قطبیت خنثی نیز می‌باشند که در محدوده این پژوهش نمی‌باشد.

تجزیه و تحلیل احساسات در سه سطح مورد بررسی قرار می‌گیرد [۹]، [۱۰]. تعیین قطبیت در سطح یک سند متنی که به تعیین احساسات کل سند به عنوان یک موجودیت خاص می‌پردازد. تعیین قطبیت در سطح جمله که برای طبقه‌بندی ذهنیت استفاده می‌شود و بررسی می‌کند که آیا یک جمله حاوی حقایق یا احساسات و عقاید است [۱۱]. در نهایت تعیین قطبیت در سطح جنبه که یک موضوع بسیار چالش‌برانگیز است و

مختلفی مانند تجزیه و تحلیل نظرات کاربران وبگاه‌های فروش، نظرات کاربران وبگاه‌های آموزشی، نظرات کاربران صفحات اجتماعی و مشابه آن استفاده می‌شود. Kharde و همکاران [۷] مدلی را برای طبقه‌بندی توییت‌ها پیشنهاد کرده‌اند. آنها توییت‌های شبکه‌های اجتماعی توییت را جمع‌آوری کرده و سپس با استفاده از مدل چندعاملی بیز ساده آنها را طبقه‌بندی می‌نمایند.

تجزیه و تحلیل نظرات افراد در مورد موضوعات فارسی در پیام‌های تلگرام توسط کشاورزی و همکاران ارائه شده است [۶]. آنها با استفاده از روش‌های مبتنی بر قانون و با بهره‌گیری از کیسه کلمات به تحلیل نظرات کاربران پرداخته‌اند. طبقه‌بندی نظرات بر روی محصولات پوشاک با زبان چینی نیز توسط Zhang و همکاران [۲۰] ارائه شده است. در این تحقیق از روش تبدیل کلمه به بردار ویژگی برای استخراج ویژگی استفاده شده است؛ سپس طبقه‌بندی نظرات به دو دسته مثبت و منفی با استفاده از ماشین بردار پشتیبان انجام شده است.

برای تعیین قطبیت متون، می‌توان مدلی مستقل از زبان و دامنه ارائه داد. بادپیما و همکاران [۲۱] از ترکیب شبکه‌های بازگشتی حافظه طولانی کوتاه مدت برای استخراج ویژگی و از ماشین بردار پشتیبان برای طبقه‌بندی متون فارسی در سه طبقه مثبت، منفی و خنثی استفاده کرده‌اند. در این مدل، بعد از پیش‌پردازش و استخراج کیسه کلمات، از متن خام به‌عنوان ورودی شبکه‌های بازگشتی مذکور استفاده شده است. در ادامه از بردارهای حاصل از خروجی این شبکه میانگین گرفته شده و در نهایت طبقه‌بندی توسط ماشین بردار پشتیبان انجام شده است. تجزیه و تحلیل احساسات زبان عربی توسط Ombabi و همکاران [۲۲] ارائه شده است. در این مدل از یک لایه کانولوشن برای استخراج ویژگی‌های محلی و از دو لایه حافظه طولانی کوتاه مدت برای وابستگی طولانی استفاده شده است، سپس ویژگی‌های به دست آمده از این لایه‌ها به طبقه‌بند ماشین بردار پشتیبان داده شده و قطبیت متون به دست آمده است.

دوره‌های برخط انبوه در دسترس، رویکردهای نوآورانه اخیر در آموزش از راه دور است که یادگیری را برای شرکت‌کنندگان

روش‌های یادگیری با نظارت انجام شده است. برای این مهم در ابتدا جملات پیش‌پردازش شده تا کلمات زائد آنها حذف شود. سپس جهت بازنمایی داده‌های متنی به عددی روش‌های استخراج ویژگی مختلف شامل بردار رخداد<sup>۱</sup>، فراوانی اصطلاح-معکوس فراوانی سند<sup>۲</sup> و تعیبه کلمات<sup>۳</sup> بررسی شده است. بعد از آن، از رویکردهای یادگیری ماشین با نظارت در دو دسته روش‌های کلاسیک و روش‌های یادگیری عمیق جهت تعیین احساسات استفاده شده است. در روش‌های کلاسیک چندین رویکرد مشهور که در کاربردهای مختلف کارایی خوبی را نشان داده‌اند، شامل روش‌های ماشین بردار پشتیبان<sup>۴</sup>، درخت تصمیم<sup>۵</sup>، K نزدیک‌ترین همسایه<sup>۶</sup>، بیز ساده<sup>۷</sup> و رگرسیون منطقی<sup>۸</sup> بررسی شده‌اند. تلفیق تصمیم<sup>۹</sup> یکی از رویکردهای معروف در یادگیری ماشین جهت افزایش کارایی طبقه‌بندی است. در این روش برچسب یک نمونه بر اساس خروجی چند طبقه‌بندی کننده مشخص می‌شود. در این جا کارایی تلفیق تصمیم در روش‌های کلاسیک نیز بررسی شده است. در سال‌های اخیر روش‌های مبتنی بر یادگیری عمیق در حوزه‌های مختلف با موفقیت خوبی به کار گرفته شده‌اند. علاوه بر روش‌های کلاسیک، چند روش یادگیری عمیق شامل شبکه عصبی عمیق<sup>۱۰</sup>، شبکه عصبی پیچشی<sup>۱۱</sup> و شبکه‌های حافظه طولانی کوتاه مدت<sup>۱۲</sup> یک طرفه و دوطرفه نیز بررسی شده است. در نهایت ارزیابی نتایج تمامی روش‌ها انجام شده و با تحلیل نتایج، بهترین رویکرد برای تعیین احساسات پیشنهاد شده است.

## ۲. پیشینه تحقیق

طبقه‌بندی احساسات بر روی داده‌های متنی در کاربردهای

<sup>1</sup> Count Vectorizer

<sup>2</sup> Term Frequency-Inverse Document Frequency (TF-IDF)

<sup>3</sup> Word Embedding

<sup>4</sup> Support Vector Machine (SVM)

<sup>5</sup> Decision Tree (DT)

<sup>6</sup> K-Nearest Neighbors (KNN)

<sup>7</sup> Naïve Bayes (NB)

<sup>8</sup> Logistic Regression (LR)

<sup>9</sup> Decision Fusion

<sup>10</sup> Deep Neural Network (DNN)

<sup>11</sup> Convolutional Neural Network (CNN)

<sup>12</sup> Long Short-Term Memory (LSTM)

معکوس فراوانی سند استفاده شده است و کلماتی با امتیاز بیشتر برای ایجاد واژگان انتخاب شده است. سپس از شبکه عصبی بازگشتی برای تعیین قطبیت این پیام‌ها استفاده شده است.

تجزیه و تحلیل احساسات بر روی متون طولانی و متون کوتاه انجام می‌شود. بصیری و همکاران [۲۸] مدلی را با ترکیب روش‌های شبکه عصبی پیچشی و شبکه عصبی بازگشتی برای تجزیه و تحلیل احساسات پنج مجموعه داده انگلیسی شامل متون طولانی و سه مجموعه داده توئیتر با متون کوتاه مورد ارزیابی قرار دادند. در این مدل از روش تعبیه کلمات برای تبدیل متن به بردار استفاده شده است و از مجموعه از پیش آموزش داده شده Glove برای وزن‌های لایه تعبیه مدل استفاده شده است. همچنین از شبکه بازگشتی دوطرفه برای استخراج هر دو وابستگی مفاهیم گذشته و آینده برای نمایش معنایی متن بهره گرفته شده است.

در سال اخیر بیماری کوید ۱۹ سلامتی مردم جهان را تحت تاثیر قرار داده است. اخبار این بیماری همه‌گیر در رسانه‌های اجتماعی در سراسر جهان به اشتراک گذاشته می‌شود. Rustam و همکاران [۲۹] به تجزیه و تحلیل ۷۵۲۸ توئیتهای مربوط به این بیماری پرداخته‌اند. آنها از روش‌های یادگیری ماشین کلاسیک از جمله درخت تصمیم و جنگل تصادفی و روش یادگیری عمیق بازگشتی حافظه طولانی کوتاه مدت برای طبقه‌بندی نظرات کاربران در سه دسته مثبت، منفی و خنثی استفاده کردند.

با توجه به مطالعات انجام شده در زمینه تجزیه و تحلیل می‌توان نتیجه گرفت که،

(۱) تجزیه و تحلیل احساس در سطح سند و جنبه به موضوع متن وابسته است،

(۲) استفاد از روش لغت‌نامه برای تجزیه و تحلیل احساسات فرآیندی زمانبر است و به نظر شخص خبره بستگی دارد،

(۳) تجزیه و تحلیل احساسات کلمات اختصار در متون انگلیسی و جملات کنایه‌ای و طنزآمیز در زبان فارسی به دلیل ساختار پیچیده زبان فارسی از جمله مواردی است که چالش برانگیز است و هنوز جای کار دارد.

بدون محدودیت سن، جنس، نژاد و جغرافیا فراهم می‌کند. تجزیه و تحلیل داده‌های آموزشی می‌تواند بازخوردهایی را از آموزش داشته باشد. این تجزیه و تحلیل می‌تواند به معلمان برای بهبود عملکرد آموزش کمک کند. Onan [۲۳] به تجزیه و تحلیل پایگاه داده مروری شامل ۶۶۰۰۰ نظر با استفاده از روش‌های یادگیری ماشین، یادگیری دسته جمعی<sup>۱</sup> و روش‌های یادگیری عمیق پرداخته است.

در سال‌های اخیر روش‌های یادگیری عمیق توجه بسیاری از پژوهش‌ها را به خود جلب کرده‌اند و توانسته‌اند کارایی خوبی را در کاربردهای مختلف از خود نشان دهند. Wang و همکاران [۲۴] روشی را برای تجزیه و تحلیل جملات کوتاه ارائه دادند. آنها از ترکیب دو شبکه عصبی پیچشی برای استخراج ویژگی‌های محلی و شبکه عصبی بازگشتی برای وابستگی‌های طولانی بین کلمات استفاده کردند و روش پیشنهادی خود را بر روی سه پایگاه داده مختلف نظرات انگلیسی برای نقد فیلم ارزیابی کردند.

تجزیه و تحلیل احساسات به زبان انگلیسی بر روی ۷ پایگاه داده مختلف توسط Dang و همکاران بررسی شده است [۲۵]. آنها از دو روش فراوانی اصطلاح-معکوس فراوانی سند و تعبیه کلمات برای استخراج ویژگی استفاده کردند؛ سپس داده‌ها با بکارگیری روش‌های یادگیری عمیق، شبکه عصبی پیچشی و شبکه عصبی بازگشتی طبقه‌بندی شدند.

از ترکیب روش‌های آماری و مبتنی بر دانش برای تجزیه و تحلیل احساسات متون می‌توان استفاده کرد. Yang و همکاران [۲۶] از این مدل برای بررسی متون چینی استفاده کردند. آنها از روش مبتنی بر دانش برای افزایش ویژگی‌های احساسات و از شبکه‌های عصبی پیچشی و شبکه عصبی بازگشتی برای تعیین قطبیت متون استفاده کردند.

محمدی و همکاران [۲۷] مدلی با استفاده از یادگیری عمیق برای تجزیه و تحلیل پیام‌های فارسی تلگرام ارائه کردند. در این مدل برخلاف سایر روش‌ها به جای استفاده از کلمات پرتکرار برای تولید واژگان، از روش امتیازدهی فراوانی اصطلاح -

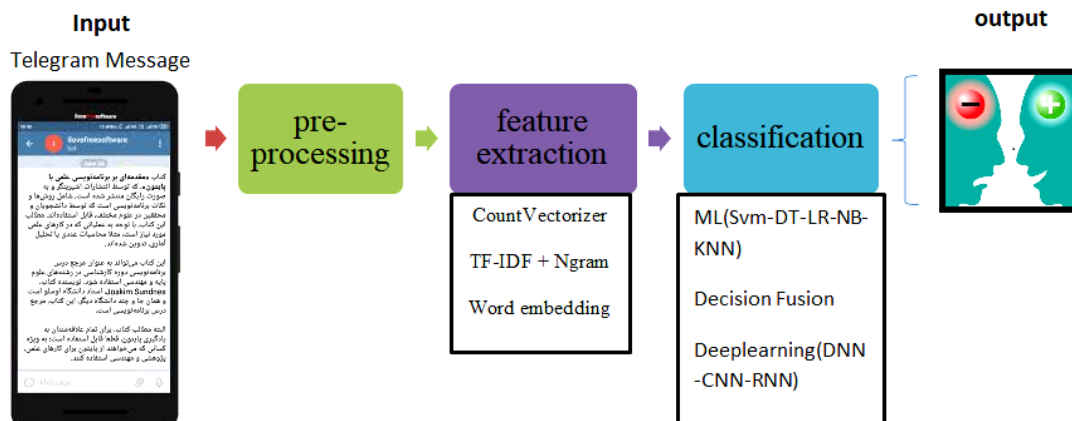
<sup>۱</sup> Ensemble Learning

پیش پردازش بر روی داده‌ها، استخراج ویژگی و طبقه‌بندی کردن داده‌ها انجام شده است. در مرحله نخست، داده‌ها پیش پردازش شده و کلمات زائد از داده‌ها حذف می‌شوند. سپس ویژگی‌های مناسب از داده‌ها استخراج شده و در نهایت مدل طبقه‌بندی کننده آموزش داده می‌شود. در ادامه جزئیات هر یک از مراحل روش پیشنهادی شرح داده شده است.

در این پژوهش برآنیم که انواع روش‌های استخراج ویژگی و روش‌های یادگیری ماشین کلاسیک و یادگیری عمیق را برای تجزیه و تحلیل احساسات پیام‌های فارسی تلگرام بررسی کنیم.

### ۳. روش پیشنهادی

شمای کلی از روش پیشنهادی در شکل (۱) نشان داده شده است. این روش پیشنهادی در چهار مرحله جمع‌آوری داده‌ها،



شکل (۱): روند نمای روش پیشنهادی

۲. کلمات متوقف کننده: این کلمات هیچ نقشی در تعیین احساسات ندارند. نمونه‌ای از این کلمات «است»، «باید»، «از» و «تا» می‌باشند.
۳. اعداد و کاراکترهای خاص: کاراکترهایی مانند @, #, \$, %, & و اعداد فارسی و انگلیسی باید از پیام‌ها حذف شوند.
۴. حروف و کلمات غیرفارسی: تمامی حروف و کلمات غیر از زبان فارسی باید حذف شوند.
۵. شکلک‌ها: با وجود اینکه شکلک‌ها ساده‌ترین روش تشخیص حالت نویسنده است، اما با توجه به اینکه برخی از کاربران از شکلک‌ها به درستی استفاده نمی‌کنند، بهتر است که شکلک‌ها هم از پیام‌ها حذف شوند.
۶. علامت‌های جمع: علائم جمع مانند «ها» در «درخت‌ها» هیچ نقشی در تعیین احساسات ندارند، پس بایستی از پیام‌ها حذف شوند.

### ۳.۱. جمع‌آوری داده

این پژوهش بر روی پیام‌های تلگرام انجام شده است. به منظور جمع‌آوری داده از سامانه ایده‌کاو<sup>۱</sup> که با داده‌های تلگرام سروکار دارد استفاده شده است. در سامانه ایده‌کاو از مجموع ۸۵۷۴۱ جمله استخراج شده از این سامانه، ۴۶۵۱۷ جمله دارای احساس با برچسب منفی و ۳۹۲۲۴ جمله دارای احساس با برچسب مثبت است.

### ۳.۲. پیش پردازش داده

پیام‌های خام تلگرام دارای افزونگی و موارد اضافه زیادی هستند که در مرحله پیش پردازش باید این موارد از پیام‌ها حذف شوند. مهم‌ترین پیش پردازش‌های انجام شده در این مرحله شامل موارد زیر می‌باشند [۶]:

۱. پیوندها و آدرس‌ها: تمام پیوندها و آدرس وبگاه‌ها یا پست‌های الکترونیکی باید از پیام‌ها حذف شوند.

<sup>1</sup> idekav.com/idekav/explore/home

### ۳.۳. استخراج ویژگی

$$TF - IDF_{t,d} = TF_{t,d} \times IDF_t \quad \text{where } IDF_t = \log_{DF_t} N \quad (1)$$

در این رابطه  $TF_{t,d}$  بیانگر تعداد تکرار کلمه  $t$  در سند  $d$ ،  $DF_t$  تعداد اسناد شامل کلمه  $t$  و  $N$  تعداد کل اسناد در مجموعه است. بنابراین، این روش از اختصاص نمره بالا به کلمات پرتکرار (مانند «است») خودداری می‌کند [۲۹]. در روش فراوانی اصطلاح - معکوس فراوانی سند همراه با مدل‌های  $N$  تایی یکتایی<sup>۱</sup>، دوتایی<sup>۲</sup> و سه‌تایی<sup>۳</sup> جهت استخراج ویژگی برای طبقه‌بندی‌کننده‌های کلاسیک و از روش تعبیه کلمات برای تبدیل پیام به ماتریسی از اعداد جهت استفاده در طبقه‌بندی‌کننده‌های یادگیری عمیق استفاده شده است. در ادامه توضیح این روش‌ها آورده شده است.

#### ۳.۳.۱. بردار رخداد

این روش متن را به یک ماتریس از اعداد صحیح تبدیل می‌کند (در واقع یک بردار خلوت از اعداد را تولید می‌کند). برای این منظور ابتدا تمام کلمات منحصر به فرد درون پایگاه داده تعیین می‌شوند. سپس برداری به طول تعداد کلمات منحصر به فرد ساخته می‌شود. برای نمایش یک جمله، مقدار مولفه مربوط به کلماتی که در جمله وجود دارد برابر با یک و بقیه مولفه‌ها برابر با صفر مقداردهی می‌شوند [۲۹].

#### ۳.۳.۲. فراوانی اصطلاح - معکوس فراوانی سند

این روش اهمیت یک کلمه در یک مجموعه را نشان می‌دهد و از دو بخش فراوانی اصطلاح و معکوس فراوانی سند تشکیل شده است. این روش یکی از معروف‌ترین بازنمایی‌های متن است و نه تنها تعداد دفعات کلمه در یک سند را در نظر می‌گیرد بلکه ارتباط یک کلمه در کل مجموعه اسناد را هم در نظر می‌گیرد.  $TF$  تعداد دفعاتی که یک کلمه در یک سند تکرار شده است و  $IDF$  تعداد تکرار هر کلمه در همه اسناد را نشان می‌دهد. رابطه (۱) چگونگی محاسبه این روش را نشان می‌دهد.

- **Unigram**: هر یک از کلمات درون جمله به تنهایی Unigram را شکل می‌دهند، مانند «این»، «فیلم»، «جذاب»، «نبود».
- **Bigram**: ترکیب دوتایی کلمات درون جمله Bigram را تولید می‌کنند، مانند «این فیلم»، «فیلم جذاب»، «جذاب نبود».
- **Trigram**: مجموعه‌ای سه‌تایی از کلمات درون جمله Trigram را شکل می‌دهند، مانند «این فیلم جذاب»، «فیلم جذاب نبود».

#### ۳.۳.۳. ماتریس کلمات تعبیه شده

برای تبدیل متن به داده قابل ارائه به شبکه عمیق دو روش کدگذاری وان‌هات<sup>۴</sup> و روش تعبیه کلمات وجود دارد. در روش اول باید به هر کلمه برداری اختصاص داده شود که طول این بردار به تعداد کلمات موجود در واژگان است و تنها یک درایه از بردار، دارای مقدار یک و سایر درایه‌ها دارای مقدار صفر هستند، هر درایه از این بردار به یک کلمه انتساب داده می‌شود. بردار تولید شده در روش وان‌هات بسیار خلوت است و تمام درایه‌های آن به جز یک درایه صفر است. علاوه بر این در روش

<sup>1</sup> Unigram

<sup>2</sup> Bigram

<sup>3</sup> Trigram

<sup>4</sup> One-Hot Encoding

وان‌هاست مستقل از پیام از قبل مشخص است که به هر کلمه چه عددی نسبت داده می‌شود، اما روش دوم یعنی روش ماتریس کلمات تعبیه شده جملات را توسط یک ماتریس متراکم نشان می‌دهد که اکثر درایه‌های آن دارای مقدار است و تعداد درایه‌های کمتری نسبت به روش وان‌هاست دارد. همچنین مقادیر این ماتریس از روی داده‌های آموزشی و متناسب با جملات یاد گرفته می‌شود [۲۶].

در این پژوهش از روش ماتریس تعبیه کلمات برای تبدیل متن به ماتریس ویژگی استفاده شده است. هر سطر این ماتریس مربوط به بازنمایی یک کلمه است که معنای لغت و محتوای آن را با یک بردار  $n$  بعدی از مقادیر عددی نمایش می‌دهد. ساخت این ماتریس به گونه‌ای انجام می‌شود که بردار کلمات هم‌معنی مشابه و بردار کلمات غیرهم‌معنی متفاوت است. در اینجا سه رویکرد مختلف جهت ایجاد ماتریس کلمات بررسی شده است: رویکرد اول: استخراج ماتریس کلمات تعبیه شده از روی پایگاه داده مورد بررسی در این پژوهش. در این رویکرد ماتریس کلمات تعبیه شده از روی لغت‌نامه ایجاد شده از روی کلمات پرتکرار در پایگاه داده ایجاد می‌گردد. تعبیه کلمات به کلمات مشابه یا هم‌معنی بردارهای مشابه‌ای می‌دهد. به عنوان مثال دو کلمه «خوب» و «مطلوب» که تقریباً هم‌معنی هستند بردارهای مشابه می‌گیرند. برای این رویکرد از کتابخانه gensim استفاده شده است. ماتریس کلمات استخراج شده توسط این کتابخانه، به عنوان وزن لایه تعبیه شبکه قرار داده شده و در مرحله طبقه‌بندی این لایه می‌تواند ثابت و بدون آموزش یا به عنوان وزن اولیه لایه تعبیه در نظر گرفته شود و در فرآیند آموزش شرکت کند.

وان‌هاست مستقل از پیام از قبل مشخص است که به هر کلمه چه عددی نسبت داده می‌شود، اما روش دوم یعنی روش ماتریس کلمات تعبیه شده جملات را توسط یک ماتریس متراکم نشان می‌دهد که اکثر درایه‌های آن دارای مقدار است و تعداد درایه‌های کمتری نسبت به روش وان‌هاست دارد. همچنین مقادیر این ماتریس از روی داده‌های آموزشی و متناسب با جملات یاد گرفته می‌شود [۲۶].

در این پژوهش از روش ماتریس تعبیه کلمات برای تبدیل متن به ماتریس ویژگی استفاده شده است. هر سطر این ماتریس مربوط به بازنمایی یک کلمه است که معنای لغت و محتوای آن را با یک بردار  $n$  بعدی از مقادیر عددی نمایش می‌دهد. ساخت این ماتریس به گونه‌ای انجام می‌شود که بردار کلمات هم‌معنی مشابه و بردار کلمات غیرهم‌معنی متفاوت است. در اینجا سه رویکرد مختلف جهت ایجاد ماتریس کلمات بررسی شده است: رویکرد اول: استخراج ماتریس کلمات تعبیه شده از روی پایگاه داده مورد بررسی در این پژوهش. در این رویکرد ماتریس کلمات تعبیه شده از روی لغت‌نامه ایجاد شده از روی کلمات پرتکرار در پایگاه داده ایجاد می‌گردد. تعبیه کلمات به کلمات مشابه یا هم‌معنی بردارهای مشابه‌ای می‌دهد. به عنوان مثال دو کلمه «خوب» و «مطلوب» که تقریباً هم‌معنی هستند بردارهای مشابه می‌گیرند. برای این رویکرد از کتابخانه gensim استفاده شده است. ماتریس کلمات استخراج شده توسط این کتابخانه، به عنوان وزن لایه تعبیه شبکه قرار داده شده و در مرحله طبقه‌بندی این لایه می‌تواند ثابت و بدون آموزش یا به عنوان وزن اولیه لایه تعبیه در نظر گرفته شود و در فرآیند آموزش شرکت کند.

رویکرد دوم: آموزش ماتریس کلمات تعبیه شده از روی پایگاه داده تلگرام همزمان با طبقه‌بندی. در این حالت ماتریس کلمات تعبیه شده همزمان با حل مساله اصلی (که در اینجا تشخیص احساس است) آموزش داده می‌شود. به طوری که در ابتدا شبکه لایه مربوط به ماتریس تعبیه کلمات را به صورت تصادفی مقداردهی اولیه کرده و در طول آموزش شبکه برای تشخیص احساس، لایه تعبیه کلمات نیز آموزش داده می‌شود. در اینجا

### ۳.۴. طبقه‌بندی پیام‌ها

در مرحله آخر بعد از اینکه پیام‌ها به صورت بردار یا ماتریس عددی بازنمایی شدند، پیام‌ها باید در دو دسته مثبت و منفی طبقه‌بندی شوند. برای انجام این کار از دو طبقه‌بندی کلاسیک و یادگیری عمیق استفاده شده است که در ادامه به صورت مختصر به هر یک پرداخته می‌شود.

#### ۴.۳.۱. روش‌های طبقه‌بندی کلاسیک

در روش‌های طبقه‌بندی کلاسیک پنج روش ماشین بردار پشتیبان، درخت تصمیم، بیز ساده،  $K$  نزدیک‌ترین همسایه و رگرسیون منطقی بررسی شده‌اند. در این قسمت توضیح بسیار مختصری در مورد این روش‌ها آورده شده است.

ماشین بردار پشتیبان. این روش یکی از مشهورترین روش‌هاست که عمومیت<sup>۱</sup> بسیار بالایی را ایجاد می‌کند. ایده اصلی در این روش یافتن ابرصفحه جداکننده است، به صورتی که بیش‌ترین فاصله بین ابرصفحه و نمونه کلاس‌ها ایجاد شود و در نتیجه عمومیت مدل افزایش یابد [۲۹]، [۳۰].

روش درخت تصمیم. طبقه‌بند درخت تصمیم، فضای داده آموزشی را به صورت سلسله مراتبی تقسیم می‌کند. این روش به طور مکرر مجموعه داده‌ها را بر اساس معیاری که جداسازی را حداکثر می‌کند، تقسیم می‌نماید. که در آن از شرط بر روی

<sup>۱</sup> Generalization

برای تعیین نهایی برچسب داده‌ها از رای‌گیری بین خروجی طبقه‌بندها استفاده شده و برچسب نهایی بر اساس رای اکثریت طبقه‌بندها مشخص می‌شود.

#### ۴.۳.۳. روش‌های طبقه‌بندی یادگیری عمیق

در سال‌های اخیر یادگیری عمیق برای حل بسیاری از مسائل پردازش زبان طبیعی مورد استفاده قرار گرفته است. اصلی‌ترین مزیت این رویکرد، عدم نیاز به تنظیم دستی و استخراج ویژگی‌ها به صورت خودکار است [۲۰]. در اینجا چهار معماری شبکه عصبی عمیق، شبکه عصبی پیچشی، شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت یک طرفه و شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت دوطرفه برای تشخیص احساسات پیام‌ها در نظر گرفته شده‌اند که در ادامه به توضیح مختصر از هر یک از آنها پرداخته شده است.

شبکه عصبی عمیق. یک شبکه عصبی عمیق از یک لایه ورودی، چند لایه میانی یا پنهان و یک لایه خروجی تشکیل شده است که مقدار خروجی به صورت تابعی از ورودی‌ها به دست می‌آید [۲۴]. ساختار شبکه عصبی عمیق پیشنهادی در این پژوهش بدین صورت است که در ابتدا یک لایه تعبیه، پس از آن ۵ لایه پنهان کاملاً متصل با تعداد ۱۲۸ نرون و در انتها لایه خروجی با یک نرون برای تعیین خروجی در نظر گرفته شده است. در این معماری در هر لایه پنهان برای جلوگیری از پیش‌برازش به اندازه  $0/2$  وزن‌ها حذف می‌شوند. شکل (۲) این معماری و پارامترهای آن را نمایش می‌دهد.

شبکه عصبی پیچشی. شبکه عصبی پیچشی در کاربردهای مختلف بینایی کامپیوتر و همچنین پردازش زبان طبیعی استفاده شده است. یکی از مزایای این شبکه، استفاده از انسجام مکانی محلی با استفاده از عملگر کانولوشن است. شبکه عصبی پیچشی از سه لایه اصلی با نام‌های لایه کانولوشن، لایه پولینگ و لایه کاملاً متصل تشکیل شده است. لایه کانولوشن اصلی‌ترین لایه است و وظیفه این لایه استخراج ویژگی‌ها است. به طور معمول پس از هر لایه کانولوشن یک لایه پولینگ قرار دارد که باعث کاهش تعداد پارامترها می‌شود [۲۲]، [۲۴]، [۳۳]، [۳۴]، [۳۵].

مقدار ویژگی‌ها برای تقسیم داده‌ها استفاده می‌شود تا داده‌ها به‌درستی در گره‌های برگ قرار داده شوند [۲۹]، [۳۱]، [۳۲].

روش بیز ساده. این روش یکی از رایج‌ترین و ساده‌ترین روش‌های طبقه‌بند آماری است که بر اساس تئوری بیز عمل می‌کند. در این روش از قضیه بیز برای محاسبه و پیش‌بینی احتمال یک ویژگی مشخص شده متعلق به یک کلاس خاص استفاده می‌شود. در بیز ساده ویژگی‌ها مستقل از هم در نظر گرفته می‌شوند [۲۹].

$K$  نزدیک‌ترین همسایگی. از ساده‌ترین روش‌های طبقه‌بندی است که به‌طور مستقیم از روی داده‌ها و بدون ساخت مدل طبقه‌بندی را انجام می‌دهد. تنها پارامتر قابل تنظیم برای این روش  $k$  که تعداد نقاط همسایه است، می‌باشد. برای طبقه‌بندی برچسب داده مورد بررسی بر اساس برچسب اکثریت  $k$  داده نزدیک به آن تعیین می‌شود [۳۱].

رگرسیون منطقی. این روش برخلاف نامش به منظور طبقه‌بندی استفاده می‌شود. در این روش احتمال عضویت داده در هر یک از کلاس‌ها محاسبه می‌شود و نمونه به کلاسی تعلق می‌گیرد که بیشینه احتمال را دارد [۳۱]، [۳۳].

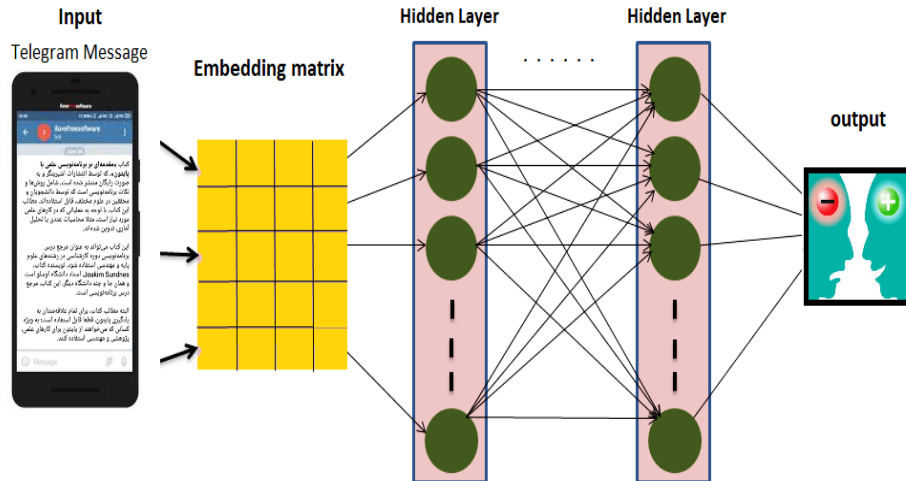
#### ۴.۳.۲. طبقه‌بندی مبتنی بر تلفیق تصمیم‌گیری

یکی از رویکردهای متداول برای بهبود مسائل طبقه‌بندی، ترکیب طبقه‌بندی‌کننده‌ها و به اصطلاح تلفیق داده جهت ارتقا تصمیم‌گیری است. تلفیق داده در دو سطح تلفیق ویژگی‌ها و تلفیق تصمیم‌گیری می‌تواند انجام شود. در تلفیق ویژگی‌ها، ویژگی‌های مختلف با یکدیگر ترکیب می‌شوند و نتیجه به یک طبقه‌بندی‌کننده داده می‌شود. اما در تلفیق تصمیم‌گیری، چند طبقه‌بندی‌کننده به صورت مستقل آموزش داده شده و نتایج خروجی آنها با یکدیگر تلفیق می‌شوند. در اینجا تلفیق تصمیم‌گیری با ترکیب خروجی طبقه‌بندی‌کننده‌های کلاسیک که در بخش قبل توضیح داده شدند، برای تعیین احساسات پیام‌های تلگرام استفاده شده است. برای این منظور داده‌ها به چند طبقه‌بند (در اینجا ۳ یا ۵ طبقه‌بند) داده شده و هر طبقه‌بند برچسب خود را به عنوان خروجی مشخص می‌کند. سرانجام




پارامترها با اندازه ۳، دو لایه کانولوشن به ترتیب با ۱۶ و ۸ فیلتر با اندازه ۳×۳، یک لایه پولینگ میانگین با اندازه ۳ و در نهایت لایه خروجی با یک نرون برای تعیین خروجی در نظر گرفته شده است. شکل (۳) پارامترهای این معماری را نشان می‌دهد.

در این پژوهش معماری پیشنهادی شبکه عصبی پیچشی به این صورت است که در ابتدا یک لایه تعبیه برای بازنمایی متن به ماتریس اعداد در نظر گرفته شده است. آنگاه دو لایه کانولوشن به ترتیب با تعداد ۶۴ و ۳۲ فیلتر با اندازه ۳×۳ برای استخراج ویژگی محلی، یک لایه پولینگ بیشینه برای کاهش تعداد



شکل (۲): معماری شبکه عصبی عمیق



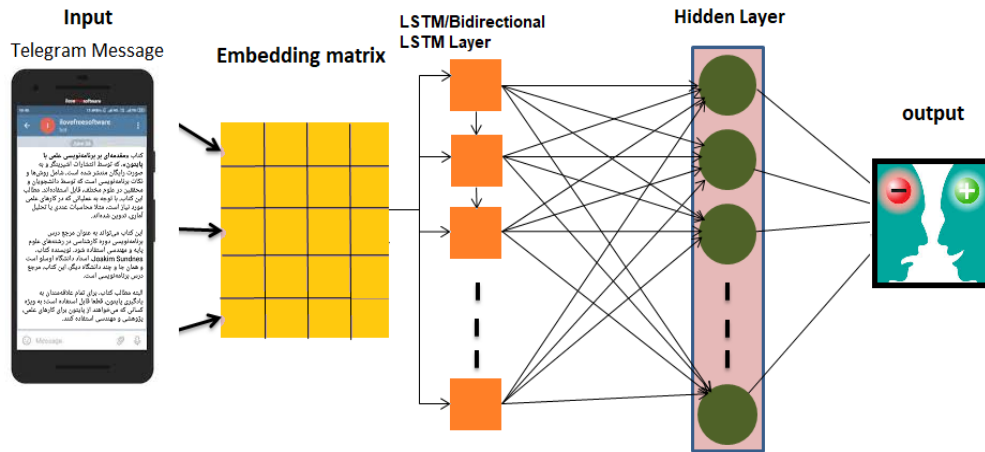
شکل (۳): معماری شبکه عصبی پیچشی

ورودی قبلی خود را به خاطر می‌سپارد و از این حافظه برای پردازش دنباله‌ای از ورودی‌ها استفاده می‌کند. شبکه عصبی حافظه طولانی کوتاه مدت یک شبکه عصبی بازگشتی است که سعی می‌کند ارتباط بین یک مولفه با مولفه‌های قبل از آن را مدل‌سازی نماید [۲۴]، [۳۶]. در معماری شبکه عصبی بازگشتی

شبکه عصبی بازگشتی. شبکه عصبی بازگشتی که به آن شبکه عصبی مکرر نیز گفته می‌شود در پردازش داده‌های ترتیبی استفاده می‌شود. این شبکه‌ها یک لایه بازخورد دارند که در آن خروجی شبکه به همراه ورودی بعدی، به شبکه بازگردانده می‌شود. شبکه عصبی بازگشتی به علت داشتن حافظه داخلی،

داشته باشد. برای در نظر گرفتن این ویژگی، شبکه عصبی حافظه طولانی کوتاه مدت دوطرفه نیز استفاده شده است که ارتباط بین یک مولفه با مولفه‌های قبل و همچنین بعد از آن را مدل‌سازی می‌کند. معماری این دو شبکه مشابه یکدیگر است؛ با این تفاوت که به جای لایه حافظه طولانی کوتاه مدت یک طرفه، از لایه دوطرفه استفاده شده است.

پیشنهادی در این پژوهش، بعد از لایه تعبیه به ترتیب یک لایه بازگشتی حافظه طولانی کوتاه مدت با تعداد ۲۰۰ سلول، یک لایه پنهان با تعداد ۱۲۸ نرون و در نهایت یک لایه با یک نرون برای تعیین خروجی در نظر گرفته شده است. شکل (۴) این مدل و پارامترهای آن را نمایش می‌دهد. در پردازش متن یک کلمه می‌تواند با کلمات قبل و همچنین بعد از خود نیز ارتباط



شکل (۴): معماری شبکه عصبی بازگشتی

#### ۴. نتایج و تحلیل آزمایش‌ها

در این مقاله ابتدا پیام‌های تلگرام همان‌طور که پیش از این در روش پیشنهادی توضیح داده شد، از سامانه ایده‌کاو دریافت شده و پیش‌پردازش‌های لازم برای حذف موارد اضافی از پیام‌ها انجام می‌شود. در این بخش روش‌های مختلف استخراج ویژگی و طبقه‌بندی که در روش پیشنهادی توضیح داده شده ارزیابی می‌شوند.

##### ۴.۱. معیارهای ارزیابی

برای ارزیابی روش‌ها از معیارهای متداول در پژوهش‌های مرتبط استفاده شده است. این معیارها که عبارتند از معیار دقت، معیار صحت، معیار فراخوان و معیار اندازه‌گیری  $F_1$  در رابطه‌های (۲) تا (۵) نشان داده شده‌اند.

نرخ دقت

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

نرخ صحت

$$P = \frac{TP}{TP + FP} \quad (3)$$

نرخ فراخوان

$$R = \frac{TP}{TP + FN} \quad (4)$$

معیار  $F_1$

$$F_1 = \frac{2 \times R \times P}{R + P} \quad (5)$$

که در این روابط مولفه  $TP$  بیان‌کننده تعداد پیام‌های مثبتی هست که به درستی توسط الگوریتم به عنوان مثبت شناسایی شده‌اند؛ مولفه  $FN$  بیانگر تعداد پیام‌هایی است که واقعا مثبت بوده ولی الگوریتم آنها را به عنوان پیام‌های منفی پیش‌بینی کرده است؛ مولفه  $FP$  بیان‌کننده تعداد پیام‌های منفی است که الگوریتم به نادرستی آنها را جز پیام‌های مثبت گزارش کرده است و مولفه  $TN$  بیان‌کننده تعداد پیام‌های منفی است که به درستی توسط الگوریتم منفی تشخیص داده شده است. در ضمن، در این مقاله از اعتبارسنجی متقابل K-Fold با مقدار K برابر ۱۰ برای ارزیابی معیارها استفاده شده است.

## ۴.۲. مقایسه روش‌های کلاسیک با انواع روش‌های استخراج ویژگی

نتایج بر اساس چهار معیار دقت، صحت، فراخوان و  $F_1$  را نشان می‌دهد. در این جدول TF-IDF1 مدل یک‌تایی، TF-IDF2 مدل یک و دوتایی و در نهایت TF-IDF3 مدل یک، دو و سه‌تایی را نشان می‌دهند. سطرها با نام Average میانگین نتایج به ازای هر روش استخراج ویژگی را گزارش می‌دهند.

در این بخش نتایج چهار روش استخراج ویژگی و چندین طبقه‌بندی‌کننده مختلف کلاسیک ارزیابی شده است. جدول (۱)

جدول (۱): مقایسه روش‌های مختلف استخراج ویژگی و طبقه‌بندی‌های کلاسیک					
روش	طبقه‌بند کلاسیک	دقت	صحت	فراخوان	$F_1$
Count Vectorizer	Logistic Regression (LR)	۸۹,۳۳	۸۹,۱۶	۸۷,۲۸	۸۸,۲۱
	SVM	۸۸,۲۷	۸۷,۸۱	۸۶,۳۶	۸۷,۰۸
	KNN(5)	۸۱,۵۹	۹۲,۱۱	۶۵,۳۶	۷۶,۴۶
	Decision Tree (DT)	۸۷,۱۶	۸۷,۸۵	۸۳,۴۹	۸۵,۶۱
	Naïve Bayse (NB)	۸۳,۶۹	۷۷,۷۱	۹۰,۲۳	۸۳,۵۱
	SVM+LR+DT	۸۹,۷۵	۸۹,۶۶	۸۷,۴۸	۸۸,۵۵
	SVM+LR+DT+NB+KNN(5)	۸۹,۶۵	۹۰,۰۶	۸۶,۹۷	۸۸,۴۹
	Average	۸۷,۰۶	۸۷,۷۶	۸۳,۸۸	۸۵,۴۱
TF-IDF1	Logistic Regression (LR)	۸۸,۲۶	۸۹,۰۷	۸۴,۷۴	۸۶,۸۵
	SVM	۸۸,۲۸	۸۸,۲۷	۸۵,۷۸	۸۷,۰۱
	KNN(5)	۷۱,۴۲	۹۴,۵۷	۳۹,۸۲	۵۶,۰۴
	Decision Tree (DT)	۸۷,۸۱	۸۷,۲۴	۸۵,۹۴	۸۶,۵۸
	Naïve Bayes (NB)	۸۵,۱۸	۸۳,۵۵	۸۴,۱۸	۸۳,۸۷
	SVM+LR+DT	۸۹,۳۰	۸۹,۷۸	۸۶,۴۴	۸۸,۰۸
	SVM+LR+DT+NB+KNN(5)	۸۸,۸۳	۹۰,۹۲	۸۳,۹۸	۸۷,۳۱
	Average	۸۵,۵۸	۸۹,۰۶	۷۸,۶۹	۸۲,۲۵
TF-IDF2	Logistic Regression (LR)	۸۸,۵۲	۹۰,۱۵	۸۴,۰۸	۸۷,۰۱
	SVM	۸۹,۴۱	۹۰,۱۴	۸۶,۳۰	۸۸,۱۸
	KNN(5)	۶۵,۰۳	۹۶,۵۹	۲۴,۴۱	۳۸,۹۷
	Decision Tree (DT)	۸۷,۹۹	۸۷,۳۶	۸۶,۲۴	۸۶,۷۹
	Naïve Bayse (NB)	۸۷,۲۶	۸۵,۲۹	۸۷,۱۹	۸۶,۲۲
	SVM+LR+DT	۸۹,۸۰	۹۰,۹۴	۸۶,۳۱	۸۸,۵۶
	SVM+LR+DT+NB+KNN(5)	۸۹,۴۱	۹۱,۷۲	۸۴,۴۹	۸۷,۹۶
	Average	۸۵,۳۴	۹۰,۳۱	۷۷	۸۰,۵۳
TF-IDF3	Logistic Regression (LR)	۸۸,۱۲	۹۰,۳۹	۸۲,۸۴	۸۶,۴۵
	SVM	۸۹,۳۳	۹۰,۴۶	۸۵,۷۰	۸۸,۰۲
	KNN(5)	۶۳,۹۵	۹۶,۵۰	۲۱,۹۸	۳۵,۸۱
	Decision Tree (DT)	۸۸,۱۴	۸۷,۵۰	۸۶,۴۲	۸۶,۹۵
	Naïve Bayse (NB)	۸۷,۶۴	۸۶,۶۴	۸۶,۲۹	۸۶,۴۶
	SVM+LR+DT	۸۹,۵۶	۹۱,۱۰	۸۵,۵۳	۸۸,۲۳
	SVM+LR+DT+NB+KNN(5)	۸۹,۱۳	۹۱,۸۰	۸۳,۷۰	۸۷,۵۷
	Average	۸۵,۱۲	۹۰,۶۳	۷۶,۰۶	۷۹,۹۳

آموزش استفاده شده است. شکل (۹) نمودارهای تابع هزینه برای داده‌های آموزش و اعتبارسنجی بر روی تمام معماری‌های یادگیری عمیق با لایه‌های تعبیه مختلف را نشان می‌دهد.

Model: "sequential"			
Layer (type)	Output Shape	Param #	
embedding (Embedding)	(None, 40, 300)	20427600	
flatten (Flatten)	(None, 12000)	0	
dense (Dense)	(None, 128)	1536128	
dropout (Dropout)	(None, 128)	0	
dense_1 (Dense)	(None, 128)	16512	
dropout_1 (Dropout)	(None, 128)	0	
dense_2 (Dense)	(None, 128)	16512	
dropout_2 (Dropout)	(None, 128)	0	
dense_3 (Dense)	(None, 128)	16512	
dropout_3 (Dropout)	(None, 128)	0	
dense_4 (Dense)	(None, 128)	16512	
dropout_4 (Dropout)	(None, 128)	0	
dense_5 (Dense)	(None, 1)	129	
=====			
	Gensim	Glove	Keras
Total params:	22,029,905	22,029,905	22,029,905
Trainable params:	1,602,305	1,602,305	22,029,905
Non-trainable params:	20,427,600	20,427,600	0

شکل (۵): پارامترهای معماری شبکه عصبی عمیق DNN

Model: "sequential"			
Layer (type)	Output Shape	Param #	
embedding (Embedding)	(None, 40, 300)	20427600	
conv1d (Conv1D)	(None, 40, 64)	57664	
conv1d_1 (Conv1D)	(None, 40, 32)	6176	
max_pooling1d (MaxPooling1D)	(None, 13, 32)	0	
conv1d_2 (Conv1D)	(None, 13, 16)	1552	
conv1d_3 (Conv1D)	(None, 13, 8)	392	
average_pooling1d (AveragePo	(None, 4, 8)	0	
dense (Dense)	(None, 4, 1)	9	
=====			
	Gensim	Glove	Keras
Total params:	20,493,393	20,493,393	20,493,393
Trainable params:	65,793	65,793	20,493,393
Non-trainable params:	20,427,600	20,427,600	0

شکل (۶): پارامترهای معماری شبکه عصبی پیچشی CNN

Layer (type)	Output Shape	Param #	
embedding_1 (Embedding)	(None, 40, 300)	20427600	
lstm_1 (LSTM)	(None, 200)	400800	
dense_2 (Dense)	(None, 128)	25728	
dense_3 (Dense)	(None, 1)	129	
=====			
	Gensim	Glove	Keras
Total params:	20,854,257	20,854,257	20,854,257
Trainable params:	426,657	426,657	20,854,257
Non-trainable params:	20,427,600	20,427,600	0

شکل (۷): پارامترهای شبکه عصبی حافظه طولانی کوتاه مدت یک طرفه

(LSTM)

بر اساس نتایج به دست آمده در جدول (۱) می‌توان گفت که در مجموع، روش تلفیقی سه طبقه‌کننده SVM، DT و LR عملکرد بهتری نسبت به سایر طبقه‌بندی‌کننده‌ها داشته‌اند. همان طور که پیش از این گفته شد، در این پژوهش از مفهوم تلفیق تصمیم، ترکیب چند طبقه‌بند برای تعیین احساس پیام‌ها نیز استفاده شده است. برای این منظور کارایی تلفیق سه طبقه‌بند با بهترین عملکرد و همچنین پنج طبقه‌بند بررسی گردید. نتایج نشان می‌دهند که تلفیق، کارایی را اندکی بهبود داده است و تلفیق سه طبقه‌بند عملکرد بهتری را به همراه داشته است. با توجه به نتایج موجود در جدول (۱)، می‌توان دریافت که روش‌های مختلف استخراج ویژگی عملکرد مشابه و نزدیک به هم داشته‌اند. با این وجود بر اساس سطرهای Average، مشاهده می‌شود که روش استخراج ویژگی اول (بردار رخداد) هم با توجه به نتایج و هم با توجه به زمان مورد نیاز برای اجرا عملکرد بهتری نسبت به سایر روش‌های استخراج ویژگی داشته است.

### ۴.۳. مقایسه روش‌های یادگیری عمیق

در این بخش برای استفاده از روش‌های یادگیری عمیق با استفاده از روش تعبیه کلمات، متن به بردارهایی از اعداد تبدیل شده و سپس از چهار معماری شبکه عصبی عمیق (با ۵ لایه پنهان کاملاً متصل به هم)، شبکه عصبی پیچشی، شبکه عصبی حافظه طولانی کوتاه مدت یک طرفه و شبکه عصبی طولانی کوتاه مدت دوطرفه استفاده شده است. پیاده‌سازی تمام این معماری‌ها در بستر Colab و بر روی TPU انجام شده است. شکل‌های (۵)، (۶)، (۷) و (۸) نمایی از معماری این شبکه‌ها را نشان می‌دهند. در هر یک از معماری‌های ذکر شده تعدادی پارامتر وجود دارد، جهت تنظیم این پارامترها از روش اعتبارسنجی متقابل<sup>۱</sup> استفاده شده است. جدول (۲) پارامترها و مقادیر آنها را نشان می‌دهد. برای جلوگیری از مساله پیش‌برازش<sup>۲</sup> از تکنیک توقف زودهنگام<sup>۳</sup> بر اساس مقدار تابع هزینه داده‌های اعتبارسنجی، برای تعیین تعداد تکرار در فرآیند

<sup>۱</sup> Cross validation

<sup>۲</sup> Overfitting

<sup>۳</sup> Early stopping

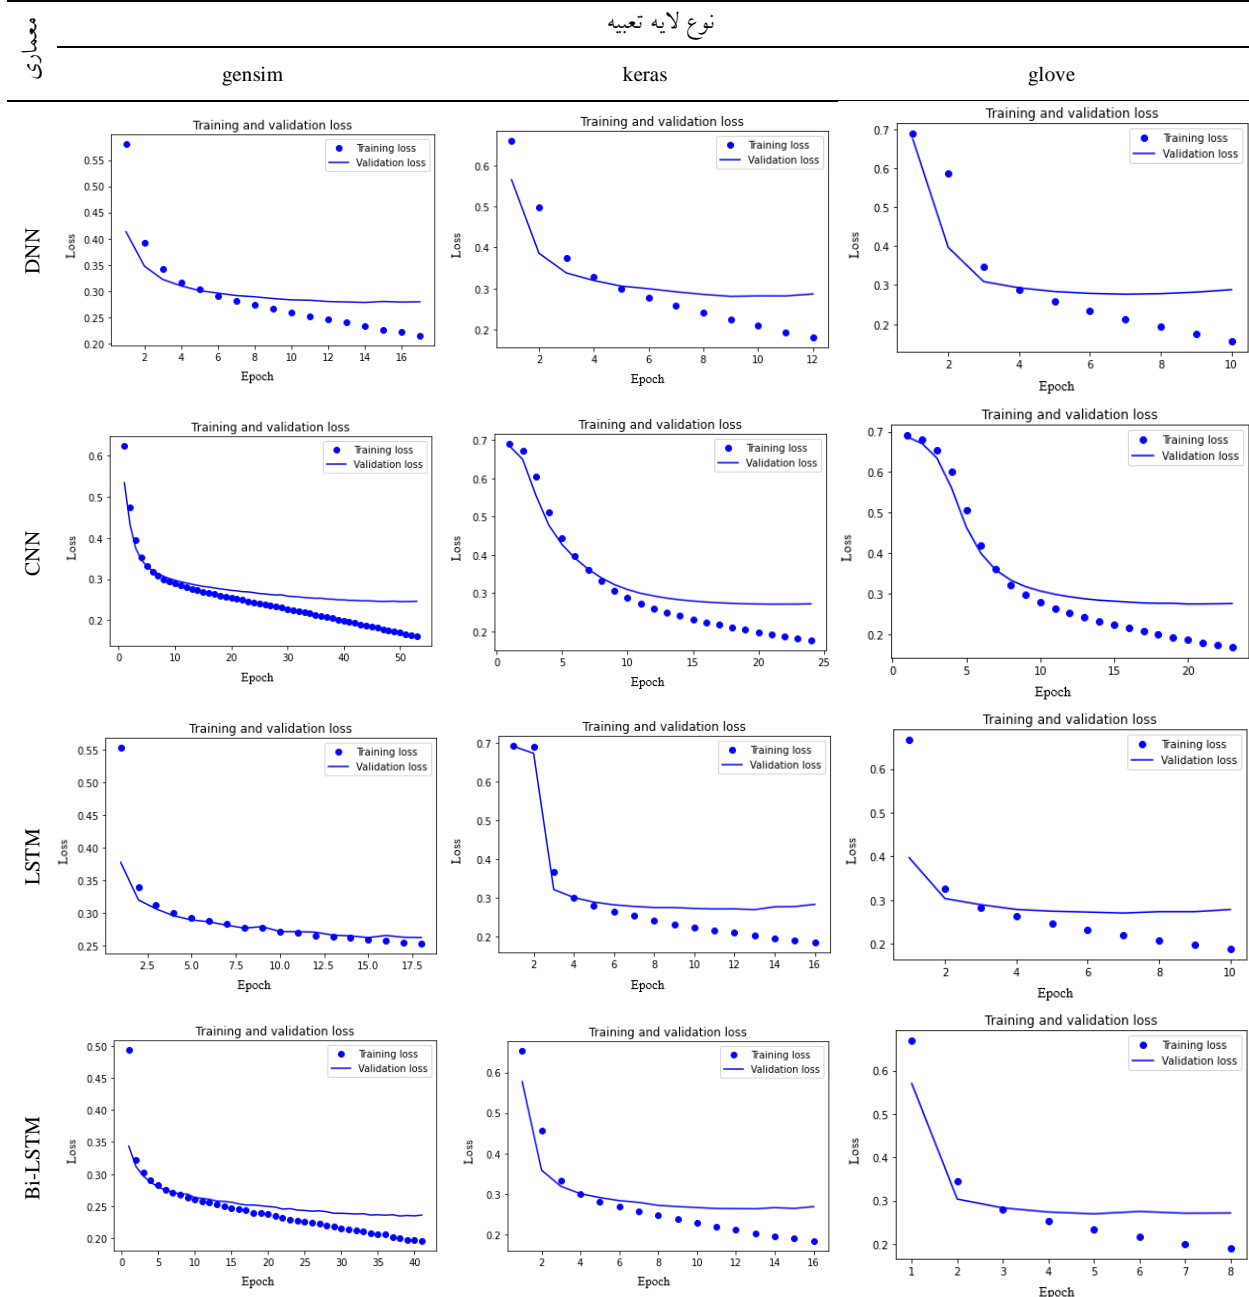
جدول (۲): پارامترهای معماری‌های یادگیری عمیق و مقادیر آنها

پارامترها	مقادیر
Epochs	Early stopping based on patience=3 on val_loss
Optimizer	Adam
Learning rate	1e-5
Batch_size	128
Loss function	binary_crossentropy

Layer (type)	Output Shape	Param #
embedding (Embedding)	(None, 40, 300)	20427600
bidirectional (Bidirectional)	(None, 400)	801600
dense (Dense)	(None, 128)	51328
dense_1 (Dense)	(None, 1)	129

Total params: Gensim 21,280,657 Glove 21,280,657 Keras 21,280,657  
 Trainable params: 853,057 853,057 21,280,657  
 Non-trainable params: 20,427,600 20,427,600 0

شکل (۸): پارامترهای شبکه عصبی حافظه طولانی کوتاه مدت دوطرفه (BIDIRECTIONAL LSTM)



شکل (۹): نمودار تابع هزینه معماری‌های مختلف با لایه‌های تعبیه مختلف

است؛ زیرا در این حالت از روی پایگاه داده مورد بررسی، به صورت بومی تعبیه کلمات واژه‌ها ساخته شده است و بنابراین عملکرد بهتری نسبت به دو روش دیگر دارد. بعد از روش gensim، روش کراس که به صورت خودکار بر روی پایگاه داده مورد بررسی، تعبیه کلمات واژه‌ها را یافته، عملکرد بهتری داشته است. اما روش glove که از تعبیه کلمات آماده شده بر روی پایگاه داده انگلیسی استفاده می‌کند، عملکرد تا حدی ضعیف‌تر نسبت به دو روش دیگر داشته است.

پس از فرآیند آموزش، نتایج معیارهای ارزیابی تمام معماری‌ها با روش‌های مختلف لایه تعبیه در جدول (۳) آورده شده است. نتایج موجود حاکی از این است که معماری شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت دوطرفه با انواع روش‌های لایه تعبیه نسبت به بقیه معماری‌ها، به دلیل در نظر گرفتن وابستگی هر کلمه با کلمات قبل و بعد از خود عملکرد بهتری داشته است. از طرف دیگر با توجه به سطر Average موجود در هر روش لایه تعبیه می‌توان گفت که روش تعبیه کلمات با استفاده از کتابخانه gensim عملکرد بهتری به همراه داشته

جدول (۳): مقایسه روش‌های مختلف لایه تعبیه و معماری‌های مختلف یادگیری عمیق

روش استفاده از لایه تعبیه	معماری یادگیری عمیق	دقت	صحت	فراخوان	$F_1$
gensim	DNN	۸۸,۷۹	۸۸,۵۹	۸۶,۶۵	۸۷,۶۱
	CNN	۹۰,۰۲	۸۸,۸۴	۸۹,۳۹	۸۹,۱۱
	LSTM	۸۹,۷۵	۸۶,۰۷	۹۰,۹۸	۸۸,۴۶
	Bidirectional-LSTM	۹۰,۶۷	۹۰,۰۱	۸۹,۵۴	۸۹,۷۷
	Average	۸۹,۸۱	۸۸,۳۸	۸۹,۱۴	۸۸,۷۴
keras	DNN	۸۸,۹۰	۸۷,۰۱	۸۹,۰۲	۸۸,۰۱
	CNN	۸۸,۹۱	۸۸,۹۷	۸۶,۴۵	۸۷,۶۹
	LSTM	۸۸,۷۱	۸۶,۲۹	۸۹,۵۳	۸۷,۸۸
	Bidirectional-LSTM	۸۹,۱۸	۸۷,۰۳	۸۹,۷۰	۸۸,۳۵
	Average	۸۸,۹۲	۸۷,۳۲	۸۸,۶۷	۸۷,۹۱
glove	DNN	۸۸,۸۲	۸۹,۵۹	۸۷,۲۰	۸۸,۳۸
	CNN	۸۸,۷۶	۸۸,۵۸	۸۶,۵۸	۸۷,۵۷
	LSTM	۸۸,۸۶	۸۸,۳۹	۸۷,۰۹	۸۷,۷۳
	Bidirectional-LSTM	۸۹,۰۲	۸۷,۷۰	۸۸,۳۶	۸۸,۰۳
	Average	۸۸,۸۶	۸۸,۵۶	۸۷,۳۱	۸۷,۹۳

خروجی سیگموئید کمتر از ۰/۵ باشد احساس جمله مثبت و اگر بیشتر از ۰/۵ باشد احساس جمله منفی در نظر گرفته خواهد شد. خروجی احتمال مدل‌ها برای هر دو جمله نشان می‌دهد که معماری شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت دوطرفه همراه با انواع لایه‌های تعبیه، با گزارش کمترین احتمال برای جمله مثبت و بیشترین احتمال برای جمله منفی، با اطمینان دقیق‌تری احساس جمله را مشخص می‌کند. دلیل این اطمینان، وجود وابستگی هر کلمه با کلمات قبلی و بعدی خود در این

#### ۴.۴. مقایسه روش‌های یادگیری عمیق و روش‌های لایه

##### تعبیه بر روی مثال عملی

در این بخش همانطور که در جدول (۴) نشان داده شده است از دو جمله با دو احساس متفاوت مثبت و منفی برای ارزیابی انواع معماری‌های یادگیری عمیق و روش‌های لایه تعبیه استفاده شده است. در تمام معماری‌ها، در لایه آخر از تابع فعال‌سازی سیگموئید برای تعیین احساس جملات استفاده شده است. اگر

دو رویکرد روش‌های کلاسیک و یادگیری عمیق نزدیک به هم می‌باشند. حال این سوال پیش می‌آید که کدام رویکرد بهتر است؟ برای پاسخ به این سوال، لازم به ذکر است که معماری‌های یادگیری عمیق در سال‌های اخیر در کاربردهای مختلف به نتایج خوبی دست یافته‌اند؛ با این وجود استفاده از این معماری‌ها با چالش‌هایی مانند نیاز به داده و زمان زیاد برای فرآیند آموزش، تنظیم پارامترهای این معماری‌ها از طریق سعی و خطا، هزینه‌بر بودن مرحله برچسب‌گذاری داده‌ها، هزینه‌های زیاد جهت پیاده‌سازی و نیاز آنها به سخت افزار GPU و TPU همراه است. لذا اگر این چالش‌ها قابل تحمل است، رویکرد یادگیری عمیق و در غیر این صورت در بسیاری از موارد الگوریتم‌های کلاسیک با صرف هزینه کمتر با عملکردی نزدیک به معماری‌های یادگیری عمیق می‌توانند انتخاب مناسبی باشند.

معماری است. همچنین از روی نتایج می‌توان نشان داد که روش لایه تعبیه gensim به دلیل ساخت تعبیه کلمات واژه‌ها از روی پایگاه داده مورد بررسی نسبت به دو روش دیگر با احتمال معقول‌تری احساس هر دو جمله را مشخص می‌کند.

#### ۴.۵. مقایسه روش‌های کلاسیک و یادگیری عمیق

در پژوهش انجام شده با توجه به جدول (۱)، در بین روش‌های استخراج ویژگی، روش بردار رخداد بر اساس میانگین معیارهای ارزیابی و از لحاظ سرعت و در بین طبقه‌بندها، روش تلفیق سه روش ماشین بردار پشتیبان، درخت تصمیم و رگرسیون منطقی بهترین عملکرد را داشته‌اند. همچنین با توجه به جدول (۳)، در روش‌های یادگیری عمیق شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت دوطرفه با لایه تعبیه gensim بهترین عملکرد را داشته است. نتایج به دست آمده از

جدول ۴: خروجی احتمالی مدلها و برچسب پیش‌بینی شده برای دو جمله نمونه

روش استفاده از	معماری یادگیری عمیق	جمله نمونه	
		حسن جوهرچی درگذشت روحش شاد و یادش گرامی (برچسب واقعی مثبت)	گواهینامه دارم مدرک دانشگاهی ندارم بیکارم خیلی به پول نیاز دارم کسی کار سراغ داره (برچسب واقعی منفی)
gensim	DNN	(+) ۰,۰۰۸۱	(-) ۰,۸۲۵۷
	CNN	(+) ۰,۰۰۴۸	(-) ۰,۸۹۴۱
	LSTM	(+) ۰,۰۰۴۰	(-) ۰,۹۰۴۴
	Bi-LSTM	(+) ۰,۰۰۰۴	(-) ۰,۹۳۴۷
keras	DNN	(+) ۰,۰۲۶۶	(-) ۰,۶۶۶۶
	CNN	(+) ۰,۰۱۹۴	(-) ۰,۷۱۷۵
	LSTM	(+) ۰,۰۰۲۱	(-) ۰,۷۵۹۸
	Bi-LSTM	(+) ۰,۰۰۱۷	(-) ۰,۸۹۳۹
glove	DNN	(+) ۰,۰۱۵	(-) ۰,۶۵۶۴
	CNN	(+) ۰,۰۰۲۴	(-) ۰,۷۰۰۲
	LSTM	(+) ۰,۰۰۴۷	(-) ۰,۷۴۳۱
	Bi-LSTM	(+) ۰,۰۰۴۵	(-) ۰,۷۵۳۲

مهم ابتدا بر روی پیام‌ها پیش‌پردازش انجام شد و افزودگی‌های مختلف از جمله پیوندها، آدرس وبگاه‌ها، علائم و شکلک‌ها از پیام‌ها حذف شدند. سپس با استفاده از دو روش بردار رخداد و فراوانی اصطلاح - معکوس فراوانی سند همراه با مدل‌های

#### ۵. نتیجه‌گیری

در این مقاله هدف تجزیه و تحلیل احساسات پیام‌های تلگرام است که از سامانه ایده‌کاو جمع‌آوری شده است. برای انجام این

وظیفه اصلی تعیین احساس پیام‌ها، وزن‌های این لایه هم تنظیم شوند. در رویکرد سوم از یک تعبیه کلمات از پیش آماده شده به نام glove بهره گرفته شد و این بردارهای از پیش آماده شده به عنوان ماتریس وزن در لایه تعبیه مورد استفاده قرار گرفت. با بررسی میانگین نتایج آزمایش‌ها بر روی داده تلگرام روش استخراج ویژگی بردار رخداد همراه با تلفیق تصمیم‌گیری با سه روش کلاسیک و روش استخراج ویژگی تعبیه کلمات همراه با شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت دوطرفه به دلیل در نظر گرفتن وابستگی هر کلمه با کلمات قبل و بعد از آن بهترین عملکرد را داشتند.

**تعارض منافع:** نویسندگان اعلام می‌کنند که هیچ تعارض منافعی ندارند.

نتایج پیام‌ها به ماتریس‌هایی از اعداد تبدیل شدند و به عنوان ورودی به روش‌های مختلفی از یادگیری ماشین داده شد. علاوه بر این از روش تلفیق تصمیم هم استفاده شده است که از چند طبقه‌بند برای تشخیص احساسات پیام‌ها استفاده کرده و با رای‌گیری بین آنها برچسب پیام مشخص می‌شود. در گامی دیگر از چهار معماری شبکه عصبی عمیق، شبکه عصبی پیچشی و شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت یک‌طرفه و دوطرفه برای طبقه‌بندی پیام‌ها استفاده شده است. به منظور بهره‌گیری از این معماری‌ها از روش تعبیه کلمات برای تبدیل متن به ماتریس‌هایی از اعداد استفاده شده است و لایه تعبیه موجود در هر چهار معماری در سه حالت مختلف تنظیم گردید. رویکرد اول با استفاده از کتابخانه gensim و کلمات موجود در پایگاه داده ابتدا تعبیه کلمات واژگان ساخته شد و سپس به عنوان ماتریس وزن اولیه به لایه تعبیه داده شد. رویکرد دوم لایه تعبیه مانند سایر لایه‌ها در فرآیند آموزش شرکت می‌کند تا همراه با

## مراجع

- [1] R. Moraes, J.F. Valiati, and W.P.G. Neto, "Document-level sentiment classification: an empirical comparison between SVM and ANN," *Expert Syst. Appl.*, vol. 40, no. 2, pp. 621–633, 2013, doi: 10.1016/j.eswa.2012.07.059.
- [2] B.N.R. Chagas, J.A.N. Viana, O. Reinhold, F.M.F. Lobato, A.F.L.J. Jr., and R. Alt, "Current applications of machine learning techniques in CRM: A Literature Review and Practical Implications," in 2018 IEEE/WIC/ACM International Conference on Web Intelligence, Santiago, Chile, December 3-6, 2018 pp. 452–458, doi: 10.1109/WI.2018.00-53.
- [3] F.A. Pozzi, E. Fersini, E. Messina, and B. Liu, "Challenges of sentiment analysis in social networks: an overview," *Sentiment Anal. Soc. Networks*, pp. 1-11, 2017, doi: 10.1016/B978-0-12-804412-4.00001-2.
- [4] A. Khosravi, H. Abdulmaleki, and M. Fayazi, "Predicting the academic status of admitted applicants based on educational and admission data using data mining techniques," *Soft Comput. J.*, vol. 9, no. 2, pp. 94-113, 2021, doi: 10.22052/scj.2021.242837.0 [In Persian].
- [5] S.A. Asghari, M. Enayati, G. Abaei, and M. R. Binesh-Marvesti, "Providing an Improved Webmining Algorithm for Semantic Web," *Soft Comput. J.*, vol. 5 no. 1, pp. 2-13, 2016 [In Persian].
- [6] M. Keshavarzi-Farashah and M.A. Zare-Chahoki, "Sentiment analysis in Persian topics based on rules integration," *Comput. Distributed Syst.*, vol. 1, no. 1, pp. 31-46, 2018 [In Persian].
- [7] V.A. Kharde and S. Sonawane, "Sentiment analysis of twitter data: a survey of techniques," *Int. J. Comput. Appl.*, vol. 139, no. 11, pp. 5–15, 2016, doi: 10.5120/ijca2016908625.
- [8] G. Wang, J. Sun, J. Ma, K. Xu, and J. Gu, "Sentiment classification: The contribution of ensemble learning," *Decis. Support Syst.*, vol. 57, pp. 77–93, 2014, doi: 10.1016/j.dss.2013.08.002.
- [9] L. Zhang, S. Wang, and B. Liu, "Deep learning for sentiment analysis: A survey," *WIREs Data Mining Knowl. Discov.*, vol. 8, no. 4, 2018, doi: 10.1002/widm.1253.
- [10] Shahnawaz and P. Astya, "Sentiment analysis: approaches and open issues," in 2017 International Conference on Computing, Communication and Automation (ICCCA), Greater Noida, India, 2017, pp. 154-158, doi: 10.1109/CCAA.2017.8229791.
- [11] A. Kumar and T.M. Sebastian., "Sentiment analysis:



- A perspective on its past, present and future,” *Int. J. Intell. Syst. Appl.*, vol. 4, no. 10pp. 1-14, 2012, doi: 10.5815/ijisa.2012.10.01.
- [12] A. Valdivia, M.V. Luzon, and F. Herrera, “Sentiment analysis in tripadvisor,” *IEEE Intell. Syst.*, vol. 32, no. 4, pp. 72–77, 2017, doi: 10.1109/MIS.2017.3121555.
- [13] W. Medhat, A. Hassan, and H. Korashy, “Sentiment analysis algorithms and applications: A survey,” *Ain Shams Eng. J.*, vol. 5, no. 4, pp. 1093–1113, 2014, doi: 10.1016/j.asej.2014.04.011.
- [14] S. Shayaa, N.I. Jaafar, S. Bahri, A. Sulaiman, S.W. Phoong, W.C. Yeong, A.Z. Piprani, and M.A. Algaradi, “Sentiment analysis of big data: methods, applications, and open challenges,” *IEEE Access*, vol. 6, pp. 37807-37827, 2018, doi: 10.1109/ACCESS.2018.2851311.
- [15] K. Mite-Baidal, C. Delgado-Vera, E. Solis-Aviles, A.H. Espinoza, J. Ortiz-Zambrano, and E. Varela-Tapia, “Sentiment analysis in education domain: a systematic literature review,” in *International Conference on Technologies and Innovation*, Guayaquil, Ecuador, 2018, pp. 285-297, doi: 10.1007/978-3-030-00940-3\_21.
- [16] K. Ahmed, N. El Tazi, and A.H. Hossny, “Sentiment analysis over social networks: an overview,” In *2015 IEEE international conference on systems, man, and cybernetics*, Kowloon Tong, Hong Kong, 2015, pp. 2174-2179, doi: 10.1109/SMC.2015.380.
- [17] O. Kolchyna, T.T.P. Souza, P. Treleaven, and T. Aste, “Twitter sentiment analysis: lexicon method, machine learning method and their combination,” *arXiv preprint arXiv: 1507.00955*, 2015, doi: 10.48550/arXiv.1507.00955.
- [18] A. Lighthart, C. Catal, and B. Tekinerdogan, “Systematic reviews in sentiment analysis: a tertiary study,” *Artif. Intell. Rev.*, vol. 54, no. 7, pp. 4997-5053, 2021, doi: 10.1007/s10462-021-09973-3.
- [19] F. Hemmatian and M.K. Sohrabi, “A survey on classification techniques for opinion mining and sentiment analysis,” *Artif. Intell. Rev.*, vol. 52, no. 3, pp. 1495-1545, 2019, doi: 10.1007/s10462-017-9599-6.
- [20] D. Zhang, H. Xu, Z. Su, and Y. Xu, “Chinese comments sentiment classification based on word2vec and SVMperf,” *Expert Syst. Appl.*, vol. 42, no. 4, pp. 1857-1863, 2015, doi: 10.1016/j.eswa.2014.09.011.
- [21] M. Badpeima, H. Shirazi, and S.S. Sadidpur, “Determining the polarity of Persian texts using LSTM recurrent networks”, in *3rd International Conference on Electrical, Electronic, and Computer Engineering*, Norway, 2016 [In Persioan].
- [22] A.H. Ombabi, W. Ouarda, and A.M. Alimi, “Deep learning CNN–LSTM framework for arabic sentiment analysis using textual information shared in social networks,” *Soc. Netw. Anal. Min.*, vol. 10, no. 1, p. 53, 2020, doi: 10.1007/s13278-020-00668-1.
- [23] A. Onan, “Sentiment analysis on massive open online course evaluations: A text mining and deep learning approach,” *Comput. Appl. Eng. Educ.*, vol. 29, no.3, pp. 572–589, 2021, doi: 10.1002/cae.22253.
- [24] X. Wang, W. Jiang, and Z. Luo, “Combination of convolutional and recurrent neural network for sentiment analysis of short texts,” in *Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers*, Osaka, Japan, 2016, pp. 2428–2437.
- [25] N.C. Dang, M.N. Moreno-García, and F. Prieta, “Sentiment analysis based on deep learning: a comparative study,” *Electronics*, vol. 9, no. 3, p. 483, 2020, doi: 0.3390/electronics9030483.
- [26] L. Yang, Y. Li, J. Wang, and R.S. Sherratt, “Sentiment analysis for e-commerce product reviews in chinese based on sentiment lexicon and deep learning,” *IEEE Access*, vol. 8, pp. 23522–23530, 2020, doi: 10.1109/ACCESS.2020.2969854.
- [27] A. Mohammadi, M.R. Pazhohan, and M. Rezaeian, “Determining the polarity of users' opinions and recognizing requests by deep learning techniques in Telegram,” in *4th Conference of Applied Research in Electrical, Mechanical, Computer and Information Technology Engineering*, Iran, 2018 [In Persian].
- [28] M.E. Basiri, S. Nemati, M. Abdar, E. Cambria, and U.R. Acharya, “ABCDM: an attention-based bidirectional CNN-RNN deep model for sentiment analysis,” *Future Gener. Comput. Syst.*, vol. 115, pp. 279–294, 2021, doi: 10.1016/j.future.2020.08.005.
- [29] F. Rustam, M. Khalid, W. Aslam, V. Rupapara, A. Mehmood, and G.S. Choi, “A performance comparison of supervised machine learning models for Covid-19 tweets sentiment analysis,” *PLOS ONE*, vol. 16, no. 2, 2021, doi: 10.1371/journal.pone.0245909.
- [30] S. Shabanizade-Rabori, V. Khatibi-Bardsiri, and A. KhatibiBardsiri, “Presentation of a new method for predicting software defect using neural network combination and grasshopper algorithm,” *J. Modeling Eng.*, vol. 17, no. 57, pp. 201-214., 2019, doi: 10.22075/jme.2019.15226.1514 [In Persian].
- [31] A. Tripathy, A. Agrawal, and S.K. Rath, “Classification of sentiment reviews using n-gram machine learning approach,” *Expert Syst. Appl.*, vol. 57, pp. 117–126, 2016, doi: 10.1016/j.eswa.2016.03.028.
- [32] H. Veisi, H.R. Ghaedsharaf, and M. Ebrahimi,

- “Improving the Performance of Machine Learning Algorithms for Heart Disease Diagnosis by Optimizing Data and Features,” *Soft Comput. J.*, vol. 8, no. 1, pp. 70-85, 2019, doi: 10.22052/8.1.70 [In Persian].
- [33] S. Dreiseitl and L. Ohno-Machado, “Logistic regression and artificial neural network classification models: a methodology review,” *J. Biomed. Informatics*, vol. 35, no. 5, pp. 352–359, 2002, doi: 10.1016/S1532-0464(03)00034-0.
- [34] F. Zare-Mehrjardi and M. Rezaian, “Presenting the 3D model of detected facial expressions in video, using deep learning method for computer games,” in *5th International Conference on Computer Games; Opportunities and challenges*, Isfahan, Iran, 2018 [In Persian].
- [35] R. Rastgoo and K. Kiani, “Face recognition using fine-tuning of Deep Convolutional Neural Network and transfer learning,” *J. Modeling Eng.*, vol. 17, no. 58, pp. 103-111, 2019 doi: 10.22075/jme.2019.16299.1613 [In Persian].
- [36] M. Moallem and A.A. Pouyan, “Anomaly Detection using LSTM AutoEncoder,” *J. Modeling Eng.*, vol. 17, no. 56, pp. 191-211, 2019, doi: 10.22075/jme.2018.12979.1270 [In Persian].