

تحلیل احساسات متون انگلیسی با استفاده از مدل‌های ترکیبی یادگیری عمیق

سیما عمادی*

گروه مهندسی کامپیوتر، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران
پست الکترونیکی: Sima.Emadi@iau.ac.ir

۱. مقدمه

با افزایش محتواهای متنی، حجم عظیمی از داده‌های متنی در حوزه کاربردهای دیجیتال ایجاد شده است که استفاده از آنها جهت افزایش رضایت مشتریان ضروری است؛ لذا با افزایش دسترسی‌پذیری و محبوبیت منابع غنی از عقاید مانند وبگاه‌های نقد و بررسی برخط، و نوشت‌های شخصی و شبکه‌های اجتماعی، فرصت‌ها و چالش‌های جدیدی در حوزه کاربردهای متن‌کاوی به نام تحلیل احساسات^۱ ایجاد شده است که فرایندی برای تشخیص احساسات در یک متن، جمله یا عبارت محسوب می‌شود. از مهم‌ترین این چالش‌ها در این زمینه، طبقه‌بندی یا تعیین قطبیت احساسات مبتنی بر جمله، شناسایی جنبه‌ها و احساسات ضمنی، منابع محاسباتی و زمان، مدل‌سازی روابط بین جنبه و چگونگی مدل‌سازی معنایی^۲ بین کلمات است [۱].

مطالعات متعددی برای تحلیل نظرات کاربران مبتنی بر روش‌های پیش‌بینی یادگیری ماشین یا یادگیری عمیق ارائه شده که هر تحقیق سعی در رفع یکی از چالش‌های موجود در طی فرایند تحلیل احساسات داشته‌اند [۲،۳]. یک چالش عمده در تحلیل احساسات، تشخیص قطبیت متن با توجه به

چکیده

با افزایش استفاده از اینترنت و شبکه‌های اجتماعی، حجم انبوهی از نظرات کاربران در ارتباط با موضوعات مختلف تولید می‌گردد. در نتیجه به‌کارگیری تکنیک‌های علمی نوین جهت تحلیل این نظرات جهت افزایش رضایت مشتریان ضروری به نظر می‌رسد. تحلیل احساسات نظرات کاربران، به‌عنوان یک راهکار ویژه و مؤثر، به دنبال کشف دانش از این متون جهت رفع چالش قطبیت آنها می‌باشد. در این تحقیق، رویکردی ترکیبی مبتنی بر دو روش یادگیری عمیق RNN-GRU و مبتنی بر تعبیه‌گذاری کلمات جهت تحلیل احساسات نظرات کاربران ارائه گردیده است. جهت بهبود تعیین قطبیت از تعبیه‌گذاری کلمات از پیش آموزش دیده شده Word2vec و GloVe استفاده شده است. نتایج ارزیابی بر روی دو مجموعه داده توییت‌های خطوط هوایی و نظرات فیلم نشان می‌دهد که روش پیشنهادی از نظر دقت در تعیین قطبیت نظرات، بهبود ۱٪ را نسبت به روش‌های ترکیبی دیگر داشته است.

واژه‌های کلیدی: تجزیه و تحلیل احساسات، یادگیری عمیق، شبکه‌های عصبی بازگشتی، شبکه عصبی واحد بازگشتی دروازه‌دار، تعبیه‌گذاری کلمات، Word2vec، GloVe.

1- Sentiment analysis
2- Semantic modeling

* نویسنده مسئول

از راه دور و عدم توانایی در انجام محاسبات موازی بر روی داده ورودی ممکن است در طول مدل‌سازی معنایی رخ دهد. مدل‌های مبتنی بر شبکه‌های عصبی پیچشی نیز توانایی بالقوه در محاسبات موازی و استخراج معنایی را دارند؛ اما این مدل‌ها فقط می‌توانند به دلیل انقباض اندازه هسته هم‌آمیختگی و ادغام^۴، رابطه فضایی محلی کلمات را بگیرند. مدل‌های مبتنی بر شبکه‌های حافظه اگر چه می‌توانند روابط معنایی با فواصل طولانی را مدیریت کنند؛ اما آن‌ها بر مؤلفه‌های حافظه واحد تمرکز دارند و در نتیجه وظایف مشخصی را در بر می‌گیرند.

بررسی‌ها نشان می‌دهد که تحقیقات کمی از روش ترکیبی مبتنی بر یادگیری عمیق با اعمال مجموعه‌ای از ویژگی‌ها مثل تعبیه کلمات، ویژگی‌های احساسی و رابطه معنایی بین کلمات به منظور تعیین قطبیت احساسات، استفاده نموده‌اند. درحالی‌که به نظر می‌رسد در نظر گرفتن این پارامترها در کنار یکدیگر برای طبقه‌بندی ضروری است؛ بنابراین، این تحقیق، یک رویکرد ترکیبی مبتنی بر شبکه عصبی بازگشتی و شبکه عصبی واحد بازگشتی دروازه‌دار (RNN-GRU) برای طبقه‌بندی نظرات کاربران در سطح جمله با استفاده از ترکیب چند ویژگی پیشنهاد می‌کند تا قطبیت نظرات مبتنی بر متن را با در نظر گرفتن رابطه معنایی بین کلمات تعیین کند. رابطه معنایی بین کلمات در قالب یک ماتریس وزن برای افزایش دقت تعیین قطبیت جملات، در لایه تعبیه‌گذاری کلمات روش پیشنهادی اعمال شده است. از آنجایی‌که اندازه مجموعه داده‌ها غالباً کوچک است به منظور تعیین رابطه معنایی بین کلمات از روش‌های تعبیه‌گذاری از پیش آموزش [۲۰-۱۶] دیده شده به نام Word2vec [۱۷] و GloVe [۱۸]، استفاده شده است.

مدل پیشنهادی متشکل از ۳ لایه است: لایه اول، لایه کدگذاری معنایی است که روابط معنایی بین کلمات را به صورت بردار ذخیره می‌کند. لایه دوم و سوم الگوریتم‌های یادگیری عمیق هستند که ورودی لایه دوم بردار عددی کلمات و ورودی لایه سوم خروجی لایه دوم

رابطه معنایی بین کلمات است که روش‌های متعددی سعی در این نوع دسته‌بندی بدون در نظر گرفتن رابطه معنایی بین کلمات در یک متن داشته‌اند که اغلب در مشخص کردن ویژگی‌های ضروری برای پیش‌بینی احساسات ناکام هستند. در حالی که رابطه معنایی بین کلمات در یک متن می‌تواند کاملاً قطبیت یک متن را تغییر دهد.

به منظور تعیین قطبیت یا به عبارتی منفی و مثبت بودن نظر کاربران در یک زمینه خاص از روش‌های متعددی همچون روش‌های مبتنی بر زبان‌شناسی محاسباتی^۲ و یادگیری ماشین استفاده می‌گردد. به عنوان مثال روش‌های بی‌زین ساده^۳، ماشین بردار پشتیبان^۴، شبکه عصبی چند لایه پرسپترون^۵، دسته‌بندی حداکثر آنتروپی^۶، رگرسیون لجستیک^۷، جنگل تصادفی^۸ و درخت تصمیم^۹ به عنوان روش‌های یادگیری ماشین برای استخراج ویژگی‌های زبان‌شناسی و غیرزبان‌شناسی استفاده شدند که روش‌های بی‌زین ساده و ماشین بردار پشتیبان به عنوان روش‌های پایه در تحلیل نظرات مبتنی بر متن معرفی شدند [۴، ۵]. روش دیگری که امروزه برای رفع چالش‌های تحلیل احساسات به کار می‌رود یادگیری عمیق است. یادگیری عمیق مدلی است که شامل بسیاری از لایه‌های پردازش اطلاعات غیرخطی و روشی برای یادگیری نمایش ویژگی‌ها در لایه‌های متوالی است [۶ و ۱۵]. این روش‌ها به سه دسته اصلی تقسیم می‌شوند: مدل‌های مبتنی بر شبکه‌های عصبی بازگشتی^{۱۱} [۷ و ۸]، مدل‌های مبتنی بر شبکه‌های عصبی هم‌آمیختگی^{۱۲} [۹ و ۱۰] و مدل‌های مبتنی بر شبکه‌های حافظه^{۱۳} [۱۱ و ۱۲]. در مدل‌های مبتنی بر شبکه‌های عصبی بازگشتی، خروجی هر حالت به حالت لحظه قبل بستگی دارد و مشکلاتی مانند از دست دادن اطلاعات احساسی

3- Computational linguistic approach

4- Naive bayes

5- Support Vector Machine

6- Multilayer Perceptron (MLP)

7- Maximum Entropy

8- Logistic Regression

9- Random Forests

10- Decision Tree

11- Recurrent Neural Network(RNN)

12- Convolution Neural Network(CNN)

13- Memory Neural Network(MemNN)

14- Pooling

مدل‌های آموزش دیده کارآمد برای یک حوزه خاص است. با این حال، اشکال اصلی این روش عدم کارایی آن هنگام اعمال بر داده‌های مختلف در دامنه‌ها است. رویکردهای یادگیری ماشین مانند بیزین ساده و ماشین‌های بردار پشتیبان بهترین طبقه‌بندها در تعیین قطبیت احساسات بیان شده‌اند [۴ و ۵].

در سال‌های اخیر، استفاده از تکنیک جدیدی که به‌عنوان یادگیری عمیق شناخته شده است، توجه پژوهشگران را به خود جلب کرده است، زیرا نتایج قابل‌توجهی را برای کارهای پردازش زبان طبیعی مختلف به دست آورده است. مدل‌های مختلفی از یادگیری عمیق برای تحقق تحلیل / طبقه‌بندی احساسات سطح جمله پیشنهاد شده‌اند که می‌توان آن‌ها را به ۴ دسته تقسیم نمود: شبکه‌های عصبی پیچشی، شبکه‌های عصبی بازگشتی، شبکه‌های از پیش آموزش دیده بدون نظارت^{۱۵} و مدل‌های ترکیبی^{۱۶}. در ادامه تحقیقات انجام شده در این سه گروه به همراه تحقیقات انجام شده به کمک الگوریتم‌های یادگیری ماشین بررسی می‌شود.

مدل‌های مبتنی بر شبکه‌های عصبی هم‌آمیختگی

کیم و همکاران [۲۱] یک مدل شبکه عصبی هم‌آمیختگی دو کانالی حاوی هسته‌های فیلتر کننده با اندازه‌های مختلف ساده و در عین حال کارآمد را بدون در نظر گرفتن رابطه معنایی بین کلمات پیشنهاد دادند که در آن هر کانال از یک لایه مجزای واحد تشکیل شده و به دنبال آن یک لایه ادغام k_{max} برای تجزیه و تحلیل احساسات سطح جمله اعمال می‌شود. این مدل کم‌عمق موفقیت زیادی کسب کرد و از این‌رو توسط محققان دیگر به‌عنوان مدل پایه استفاده می‌شود. هوانگ و همکاران نیز [۲۲]، با بهبود مدل شبکه عصبی هم‌آمیختگی، با کمک دو واحد عصبی جدید فیلترهای پارامتری و دروازه‌های پارامتری سعی نمودند اطلاعات جنبه را در معماری شبکه برای طبقه‌بندی احساسات مبتنی بر جنبه اعمال نمایند. مقایسه با روش‌های پایه نشان می‌دهد

است تا پس از پردازش‌های انجام شده، خروجی موردنظر که همان تعیین قطبیت جمله در سه سطح مثبت، منفی و خنثی است را تولید کند.

به‌طور کلی نوآوری تحقیق به شرح زیر است:

- استفاده از تعبیه‌گذاری کلمات با کمک روش از پیش

آموزش داده شده Word2vec و GloVe

- استفاده از رویکرد ترکیبی الگوریتم‌های یادگیری

عمیق RNN-GRU به‌منظور بهبود تعیین قطبیت در سطح جمله

- مقایسه دقت الگوریتم‌های ساده یادگیری عمیق با

رویکرد ترکیبی مبتنی بر تعبیه‌گذاری کلمات با کمک روش از پیش آموزش داده شده

ساختار مقاله در ادامه به شرح زیر است: در بخش

۲، تحقیقات انجام شده در زمینه تحلیل احساسات را

بیان می‌کند. بخش ۳، چارچوب روش پیشنهادی را شرح

می‌دهد، بخش ۴، به ارزیابی مدل پیشنهادی می‌پردازد و در

نهایت بخش ۵، نتیجه‌گیری بیان خواهد شد.

۲. کارهای مرتبط

در دهه‌های گذشته روش‌های متعددی برای تحلیل احساسات پیشنهاد شده‌اند. اکثر این روش‌ها مبتنی بر رویکرد زبان‌شناسی محاسباتی و رویکرد یادگیری ماشین هستند که تحقیقات نشان داده است که رویکرد یادگیری ماشین عملکرد بالاتری نسبت به رویکرد زبان‌شناسی محاسباتی دارد [۱۳ و ۱۴].

در روش‌های مبتنی بر زبان‌شناسی از کلمات بیانگر احساسات موجود در اسناد برای پیش‌بینی جهت‌گیری محتوای ذهنی در اسناد متنی استفاده می‌کنند [۱۴]. در این رویکرد، میزان تأثیرگذاری کلماتی که بیانگر احساسات در متن هستند بسیار کم است. در روش‌های مبتنی بر یادگیری ماشین اغلب برای تعیین قطبیت احساسات از مجموعه داده‌های برچسب‌گذاری شده استفاده می‌شود. مزیت این رویکرد توانایی آن برای انطباق و ساخت

15- Unsupervised pre-trained networks (UPN)

16- Hybrid approach

این مدل می‌تواند به طور مؤثر حالات احساسی و جنبه‌های خاصی را یاد بگیرد و یک بهبود قابل توجه بر روی مجموعه داده‌های SemEval 2014 نسبت به روش‌های پایه عصبی داشته باشد. اما در مدل بهبود یافته شبکه عصبی هم‌آمیختگی مبتنی بر سازوکار توجه که توسط وو و همکاران [۲۳] پیشنهاد گردید، از یک لایه رمزگذاری موقعیت نسبی جدید استفاده گردید تا اطلاعات مرتبط با موقعیت نسبی عبارات خاص در متن را ادغام نماید و با سازوکار مکانیزم توجه به روابط معنایی بین عبارات جنبه و کلمات متنی کاملاً دست یابد. نتایج آزمایش‌ها روی مجموعه داده SemEval 2014، توییت‌ها و مجموعه داده‌های چینی نشان می‌دهد که این مدل نسبت به روش‌های پیشرفته بهتر عمل می‌کند. در مدل شبکه عصبی هم‌آمیختگی دیگر که هیون و همکاران [۲۴] ارائه نمودند، سعی در به‌کارگیری میزان تأثیر اطلاعات فاصله در تحلیل احساسات سطح هدف دارند. آنها اطلاعات فاصله را بین کلمات هدف و کلمات مجاور آن برای یادگیری اهمیت هر کلمه نسبت به هدف ارائه نمودند تا محدودیت‌های موجود در تولید دستی ویژگی‌ها و محدودیت‌های ذاتی روش‌های مبتنی بر شبکه‌های عصبی بازگشتی را برطرف می‌کند. نتایج تجربی نشان داده که روش پیشنهادی نسبت به روش‌های پیشین در مجموعه داده‌های توییت تک‌هدفه و چند هدفه بهتر عمل می‌کند. در مدل شبکه‌های عصبی هم‌آمیختگی پویا^{۱۷} کلاچبرنر و همکاران [۲۵] متناوباً از یک هم‌آمیختگی عریض و لایه ادغام k-max پویا برای یادگیری ساختار معنایی جمله استفاده می‌شود تا لایه ادغام k-max به شبکه‌های عصبی هم‌آمیختگی پویا جهت مدیریت جملات با هر اندازه‌ای کمک کند. یین و همکاران [۲۶] مدل بهبود یافته دیگری از شبکه‌های عصبی پیچشی را به نام شبکه‌های عصبی پیچشی واژگانی معنایی^{۱۸} ارائه دادند که با استفاده از واژه‌نامه احساسی سنتی وردنت و ویژگی‌های معنایی کلمات با استفاده از مدل تعبیه word2vec، اطلاعات احساساتی کلمات را یاد گرفتن و اقدام به تعیین قطبیت

19- Aspect-opinion pair (AOP) identification

20- Critic learning

21- First-order logic

17- Dynamic CNN (DCNN)

18- Semantic lexical augmented CNN (SCNN)

پیش‌بینی کننده و سازگار کردن آن‌ها استفاده شده است. شبکه منتقد می‌تواند اهمیت قوانین دانش را بررسی کند. در این صورت، از قوانین دانشی که حاوی اشتباهات یا نقص‌هایی هستند، به صورت سازگارانه استفاده می‌شود تا به عملکرد خدشه‌ای وارد نشود. علاوه بر این، یک راهبرد با فیلتر جدید ایجاد شده است که می‌تواند قوانین پیچیده را در نظر بگیرد. لی و همکاران [۴۵]، سه تکنیک یادگیری عمیق شبکه پالایش انتخابی^{۲۲}، شبکه‌های عصبی با حافظه کوتاه مدت بلند و شبکه عصبی هم‌آمیختی مبتنی بر مدل رگرسیون چندگانه برای تجزیه و تحلیل احساسات را بر روی مجموعه داده‌های نظرات فیلم مقایسه نمودند. این مجموعه داده بعد از پیش پردازش به عنوان ورودی سه روش در نظر گرفته شدند تا در مرحله بعد از آموزش از نظر معیار دقت ارزیابی شوند. نتایج ارزیابی نشان می‌دهد که در حجم داده‌های مختلف، شبکه‌های عصبی با حافظه کوتاه مدت بلند از شبکه پالایش انتخابی و شبکه عصبی هم‌آمیختی دارای دقت بیشتری برای تحلیل احساسات است و دو روش شبکه پالایش انتخابی و شبکه عصبی هم‌آمیختی از نظر دقت تحلیل نظر و احساس کاربران دارای عملکردی نسبتاً مشابه است. ماندولا و همکاران [۴۶]، پیش‌بینی نظرات و احساسات مشتری در مورد محصولات آمازون را با استفاده از شبکه عصبی هم‌آمیختی انجام دادند. آنها در روش پیشنهادی خود، برای استخراج کلمات کلیدی و شناسایی موضوعات مربوطه، از یک روش موثر مدل‌سازی تخصیص با خوشه‌بندی فازی استفاده نمودند و سپس کلمات کلیدی استخراج شده با استفاده از شبکه عصبی پیچشی مبتنی بر حافظه به سه دسته (مثبت، منفی و خنثی) طبقه‌بندی می‌شوند. نتیجه آزمایش‌های نشان می‌دهد که سیستم پیشنهادی دقت در تجزیه و تحلیل احساسات را ۶ تا ۲۰ درصد نسبت به سیستم‌های موجود افزایش می‌دهد.

مدل‌های مبتنی بر شبکه‌های عصبی بازگشتی
ژارماگامبوف و همکاران [۳۰] از ادغام شبکه‌های

عصبی بازگشتی عمیق با مدل‌های درخت تصمیم^{۳۳} در کنار لایه تعبیه‌گذاری کلمات از پیش آموزش‌دیده word2vec استفاده نمودند. در این مدل طبقه‌بندی‌کننده جنگل تصادفی، برچسب احساس را به هر جمله اختصاص می‌دهد. هوانگ و همکارانش [۳۱] کدگذاری دانش نحوی در شبکه عصبی با حافظه کوتاه‌مدت بلند با ساختار درختی را برای بهبود نمایش عبارت و جمله پیشنهاد دادند. موسی و همکاران [۳۲] به منظور تغییر ساختار شبکه‌های عصبی با حافظه کوتاه‌مدت بلند دو طرفه^{۲۴} و به منظور یادگیری اطلاعات متنی از یک مدل زبانی استفاده نمودند. آنها از شبکه‌های عصبی با حافظه کوتاه‌مدت بلند دو طرفه، برای برآورد توزیع احتمال جداگانه برای هر احساس از داده‌های آموزش و یک مدل تفکیک‌کننده ساده بر اساس شبکه‌های عصبی با حافظه کوتاه‌مدت بلند دو طرفه بر روی همان مجموعه داده استفاده نمودند. سپس برای به دست آوردن نتایج بهتر هر دو مدل ترکیب شدند تا یک مدل طبقه‌بندی‌کننده ترکیبی ایجاد کنند. در شبکه عصبی با حافظه کوتاه مدت بلند دو طرفه ارائه شده توسط تنگ و همکاران [۳۳] که برای طبقه‌بندی احساسات در زبان چینی ارائه گردید، از لغت‌نامه احساس برای طبقه‌بندی مبتنی بر یک مدل مجموع وزنی ساده استفاده شده است. وانگ و همکاران [۸]، شبکه‌های عصبی با حافظه کوتاه‌مدت بلند^{۲۵} را با سازوکار توجه برای طبقه‌بندی احساسات مبتنی بر جنبه‌های مختلف در یک جمله ادغام نمودند تا عملکرد مدل را با در نظر گرفتن سازوکار توجه مقایسه نمایند. در این فرایند دو مرحله‌ای ابتدا بردار تعبیه شده از جنبه مشخص با تعبیه کلمات به عنوان ورودی‌های شبکه‌های عصبی با حافظه کوتاه‌مدت بلند در نظر گرفته می‌شوند. نتایج ارزیابی بر روی مجموعه داده SemEval 2014 نشان داد که این روش عملکرد قابل مقایسه‌ای نسبت به روش‌های پایه دارد. کیان و همکاران [۳۴] از شبکه عصبی با حافظه کوتاه‌مدت بلند مبتنی بر مدل زبانی استفاده نمودند تا با ادغام شبکه عصبی با حافظه

23- DeepRNN + DT

24- Bi-LSTM

25- Long short-term memory (LSTM)

22- Selective Refinement Network

مدل‌های مبتنی بر شبکه‌های از پیش آموزش دیده بدون نظارت

رانگ و همکاران [۳۵] یک مدل پیش‌بینی بسته‌بندی^{۲۹} مبتنی بر خودکدگذاری‌ها^{۳۰} ارائه دادند که از خودکدگذاری‌های انباشته شده با چندلایه به‌عنوان یادگیری ویژگی استفاده می‌کند و به بازنمایی سطح بالایی از داده‌ها کمک می‌کند. هر خودکدگذاری انباشته شده، لایه‌های شبکه را با داده‌های بدون برچسب، پیش آموزش می‌دهد و سرانجام شبکه با سازوکار آموزش تحت نظارت تنظیم می‌شود. جین و همکاران [۳۶] شبکه‌های باور عمیق^{۳۱} را که توسعه یافته مدل آموزش بدون نظارت ماشین بولتزمن محدود^{۳۲} است، ارائه نمودند. در ادامه جین و همکاران [۳۷]، اطلاعات موقعیت و ترتیب لغات را نیز به شبکه‌های باور عمیق اضافه نمودند تا در آموزش وزن‌های اولیه به‌صورت بدون نظارت استفاده گردد. ولاچستگاریو و همکاران [۳۸] شبکه‌های هم‌آوری مولد^{۳۳} را برای یادگیری بازنمایی‌های مفید در پردازش زبان طبیعی، به‌ویژه در تحلیل احساسات، پیاده‌سازی کردند. برخلاف دیگر مدل‌های شبکه‌های هم‌آوری مولد، تفکیک‌کننده شبکه‌های هم‌آوری مولد پیشنهادی که مبتنی بر خودکدگذار حذف‌کننده نوفه است طبقه‌بندی دودویی داده‌های واقعی یا غیرواقعی را انجام نمی‌دهد. در عوض، یک نمره به هر یک از داده‌های دریافت شده از مولد اختصاص می‌دهد. سوچر و همکاران [۳۹] ابتدا یک شبکه خودکدگذار بازگشتی^{۳۴} نیمه نظارتی را برای دسته‌بندی احساسات سطح جمله پیشنهاد کردند که نمایش برداری ابعاد کاهش‌یافته را برای یک جمله به دست می‌آورد.

مدل‌های ترکیبی

وانگ و همکارانش [۴۰] یک ساختار شبکه‌های عصبی هم‌آمیختی و شبکه‌های عصبی بازگشتی مشترک را برای طبقه‌بندی احساسات متن‌های کوتاه به‌منظور بهره‌گیری از

کوتاه‌مدت بلند با منابع زبانی مانند لغت‌نامه احساسات، کلمات نفی و کلمات تشدید، میزان تاثیرگذاری احساسات در جمله را دقیق‌تر دریافت کنند. وانگ و همکاران [۷]، چارچوب TD-Parse برای طبقه‌بندی احساسات چندهدفه را معرفی نمودند. TD-Parse از یک تجزیه‌گر وابستگی نحوی تشکیل شده است که اطلاعات نحوی برای هر هدف را با متن سمت چپ خود ترکیب می‌کند. نتایج بر روی مجموعه داده‌های تویتر نشان داده است چارچوب پیشنهادی نه تنها فرایند یادگیری را کارآمد می‌سازد بلکه می‌تواند بدون طراحی ویژگی دستی و مهندسی معماری سنگین برای مدل‌های عصبی، در دو پیکره‌زبانی تک‌هدفه و چندهدفه بهتر عمل کند. وی و همکاران [۴۷]، شبکه عصبی با حافظه کوتاه مدت بلند دو طرفه را با استفاده از سازوکار توجه چند قطبی^{۲۶} به منظور تحلیل احساسات ضمنی بهبود دادند. مدل پیشنهادی، برای بیان احساسات ضمنی مبهم و فاقد هرگونه واژه احساسی صریح، بر روی مدل‌سازی اختلاف وزن سازوکار توجه در بین قطب‌ها، متمرکز است و به کلماتی که احساسات منفی بالاتری نسبت به سایر قطب‌ها دارند، وزن بیشتری اختصاص می‌دهد. دشتی‌پور و همکاران [۴۸]، یک چارچوب ترکیبی و جدید برای تحلیل احساسات در سطح موضوع در زبان فارسی ارائه کردند که قواعد زبانی و یادگیری عمیق را برای بهینه‌سازی تشخیص قطبیت ادغام می‌کند. در نهایت، عملکرد چارچوب پیشنهادی در مقایسه با روش‌های ماشین بردار پشتیبان و رگرسیون لجستیک^{۲۷} و طبقه‌بندی‌کننده‌های DNN^{۲۸} مانند حافظه کوتاه‌مدت و شبکه‌های عصبی هم‌آمیختی ارزیابی شد. داس و همکاران [۴۹]، طبقه‌بندی احساسات را با استفاده از شبکه عصبی با حافظه کوتاه مدت بلند مدل‌سازی نمودند. آنها در این پژوهش یک رویکرد آزمایشی را برای تجزیه و تحلیل واکنش‌های احساسات عمومی در تویتر بر اساس کلمات کلیدی ارائه دادند. ارزیابی روش پیشنهادی دقت ۸۴٫۵۱٪ را در تحلیل احساسات کاربران در شبکه اجتماعی نشان می‌دهد.

29- Bagging

30- Auto-encoder based bagging prediction (AEBPA)

31- Deep Belief Networks (DBN)

32- Restricted Boltzmann Machine (RBM)

33- Generative adversarial networks (GAN)

34- Recursive Autoencoder (RAE)

26- Multipolarity Orthogonal Attention

27- Logistic regression

28- Deep Neural Networks

دو مجموعه داده نظرات فیلم^{۳۹} و توییت‌های خطوط هوایی^{۴۰} نشان داد که شبکه عصبی با حافظه کوتاه مدت بلند نتایج بهتری در مقایسه با شبکه عصبی بازگشتی ارائه می‌دهد. رویز و همکاران [۵۰]، در تحقیق خود BERT^{۴۱} و شبکه عصبی با حافظه کوتاه مدت بلند دو طرفه را برای تجزیه و تحلیل نظرات در مورد دارو، بررسی نمودند. آن‌ها نشان دادند که مدل ترکیبی شبکه عصبی با حافظه کوتاه مدت بلند دو طرفه و شبکه عصبی هم‌آمیختی بهترین نتایج را ارائه می‌دهد. نقطه ضعف شبکه عصبی هم‌آمیختی عملکرد بسیار پایین آن در مقابل مجموعه داده‌های آموزشی کوچک و مزیت آن نسبت به شبکه عصبی با حافظه کوتاه مدت بلند و مدل ترکیبی، زمان آموزش کوتاه‌تر عنوان شده است. در مقابل مدل ترکیبی شبکه عصبی با حافظه کوتاه مدت بلند دو طرفه و BERT نتایج با دقت بیشتری ارائه می‌دهد اما زمان آموزش بالا و هزینه محاسباتی قابل توجهی دارند. هیکل و همکاران [۵۱]، مدل‌های مختلف یادگیری عمیق را برای داده‌های عربی بررسی نموده تا دقت تحلیل احساسات متون عربی را بهبود بخشند. همچنین، برای پیش‌بینی احساسات توییتهای عربی در سطح جمله از یک مدل گروهی متشکل از شبکه عصبی هم‌آمیختی و مدل حافظه کوتاه مدت استفاده کردند. این روش از کلمات تعبیه شده که از قبل آموزش داده شده‌اند، استفاده می‌کند و به هیچ ویژگی مهندسی اضافی برای استخراج ویژگی‌های خاص یا ماژول‌های پیچیده نیاز ندارد.

مدل‌های یادگیری ماشین

چرلو و همکاران [۵۲]، تکنیک‌های پیشرفته تحلیل احساسات را با تکنیک مبتنی بر یک واژه‌نامه جدید و توسعه یافته مقایسه کردند. سپس، روش جدید را روی مجموعه‌ای از ۷ میلیون توییت که شامل مکالمات قبل، حین و پس از راه‌اندازی دو محصول جدید در صنعت بازی‌های ویدیویی است با هدف استخراج اطلاعاتی در مورد مزایا

مزایای ویژگی‌های محلی دانه-درشت ایجاد شده توسط شبکه عصبی هم‌آمیختی و وابستگی‌های مسافت-طولانی آموخته شده از طریق شبکه عصبی بازگشتی ارائه نمودند. در مدل ترکیبی مبتنی بر شبکه عصبی با حافظه کوتاه مدت بلند و شبکه عصبی هم‌آمیختی ارائه شده توسط گوگلا و همکاران [۴۱] از تعبیه کلمات word2vec استفاده شده است تا با در نظر گرفتن رابطه معنایی بین کلمات، دقت پیش‌بینی تعیین قطبیت جملات را افزایش دهد. چن و همکاران [۴۲] رویکرد ترکیبی مبتنی بر شبکه عصبی با حافظه کوتاه مدت بلند دو طرفه با یک حوزه تصادفی شرطی^{۳۵} و شبکه عصبی هم‌آمیختی یک‌بعدی^{۳۶} را برای بهبود تجزیه و تحلیل احساسات در سطح جمله ارائه کردند. در این رویکرد ابتدا با استفاده از شبکه عصبی با حافظه کوتاه مدت بلند دو طرفه با یک فیلد تصادفی شرطی، عبارات هدف از جمله ورودی استخراج شده و طبق تعداد هدفی که به صراحت بیان شده هر جمله طبقه‌بندی می‌شود. سپس شبکه عصبی هم‌آمیختی یک‌بعدی، قطبیت جملات بدون هدف، یک هدف و چندهدفه را به طور جداگانه پیش‌بینی می‌کند.

عبدی و همکاران [۱۳]، مدلی ترکیبی مبتنی بر شبکه عصبی بازگشتی و شبکه عصبی با حافظه کوتاه مدت بلند به منظور دسته‌بندی جملات به دو قطبیت ارائه دادند. آن‌ها در روش خود تنها بر روی جملات دو قسمتی (بین این دو جملات، کلماتی مثل اما^{۳۷}، درحالی‌که^{۳۸} و غیره وجود دارد) با در نظر گرفتن رابطه معنایی بین کلمات متمرکز شدند و جهت تعیین رابطه معنایی بین کلمات از لایه تعبیه‌گذاری کلمات از پیش تعریف شده Word2vec استفاده نمودند. چاوش و همکاران [۴۳] در تحقیق خود مقایسه‌ای بین شبکه عصبی بازگشتی و شبکه عصبی با حافظه کوتاه مدت بلند در صورت استفاده از مدل تعبیه کلمات Word2vec جهت تعیین قطبیت جملات انجام دادند. نتیجه ارزیابی بر روی

39- IMDB

40- Twitter US Airline Sentiment

41- Bidirectional Encoder Representations from Transformers

35- LSTM with a Conditional Random Field

36- 1d-CNN

37- But

38- While

اطلاعات احساسات یک جمله محاسبه و با استفاده از ماشین بردار پشتیبان، یک چارچوب طبقه‌بندی ترکیبی مبتنی بر یادگیری بدون ناظر و یادگیری با ناظر و تحلیل احساسات جدید به نام SAPCP ارائه نمودند. در نهایت آنها روش پیشنهادی خود را با رویکرد یادگیری ماشین و رویکرد مبتنی بر واژه‌نامه روی سه مجموعه داده مختلف، مقایسه کردند و نتایج ارزیابی بر روی متون کوتاه دقت قابل قبول روش پیشنهادی را نشان می‌دهد. حاجی‌پور و همکاران [۵۵]، روشی ترکیبی خودکار مبتنی بر مدل آماری و یادگیری بدون نظارت برای استخراج کلمات کلیدی در زبان فارسی ارائه کردند. در این روش، هم احتمال رخ دادن کلمه در متن و تعداد تکرار آن در نظر گرفته می‌شود و هم با آموزش مدل words2vec روی متن، مفهوم و معنای متن درک می‌شود. سپس کلماتی که با سایر کلمات دارای فاصله کمی بوده استخراج شده و با استفاده از هم‌رخدادی و روابط آماری، امتیاز هر کلمه محاسبه می‌شود. در نهایت، با استفاده از حدآستانه، کلمات با امتیاز بالاتر به عنوان کلمات کلیدی در نظر گرفته می‌شوند. ارزیابی‌ها بیانگر کارایی روش با معیار f-score، ۹۲/۵۳٪ و با ۱۱٪ افزایش نسبت به سایر روش‌های استخراج کلمات کلیدی می‌باشد.

و ننگ و همکاران [۵۶] جهت طبقه‌بندی احساسات کاربران، از مربع کای^{۵۳} به منظور انتخاب ویژگی با کمک آستانه نمره از پیش تعیین شده، استفاده نمودند. همچنین آنها رابطه بین تعداد ویژگی‌های انتخاب شده و عملکرد طبقه‌بندی احساسات را در روش‌های مبتنی بر یادگیری ماشین بررسی نمودند. روش پیشنهادی آنها این مزیت را دارد که ویژگی‌هایی را انتخاب می‌کند که از آستانه اهمیت و تأثیرگذاری بالایی برخوردار است. هودار و همکاران [۵۷] استخراج زمینه چندسطحی و همجوشی ۵۴ (تحلیل بر اساس طیف مختلفی از ویژگی‌ها مانند متن، تصویر و غیره) را برای تجزیه و تحلیل احساسات و طبقه‌بندی احساسات

و ایرادات فناوری‌ها و محصولات اعمال کردند. نتایج به دست آمده در این مطالعه امیدوارکننده است، اما همچنان تنگناها و مشکلات حل‌نشده‌ای برای استخراج و درک عمیق اطلاعات از رسانه‌های اجتماعی به ویژه توئیتر وجود دارد. ری و همکاران [۵۳]، با استفاده از مدل‌های مختلف یادگیری BERT و طبقه‌بندی جنگل تصادفی روی ویژگی‌های متنی مختلف، احساسات نظرات در مورد هتل‌ها را طبقه‌بندی کردند و نظرات را با توجه به جنبه‌های مختلف آن از جمله تمیزی، خدمات و غیره در دسته‌های مختلف قرار دادند. دویکا و همکاران [۴۳] شهیدی، روش‌گان‌های مختلف را برای تحلیل احساسات به منظور ارائه کارآمدترین روش برای طبقه‌بندی نظرات، مقایسه کردند، از جمله: رویکردهای یادگیری ماشین^{۴۲}، ماشین بردار پشتیبان، تحلیل احساسات lan-gram^{۴۳}، روش نیویز^{۴۴}، طبقه‌بندی حداکثر آنتروپی^{۴۵}، KNN^{۴۶} و KNN وزن‌دار^{۴۷}، تحلیل احساسات چندزبانه^{۴۸}، تحلیل احساسات مبتنی بر ویژگی^{۴۹}، رویکردهای مبتنی بر قانون^{۵۰} و رویکردهای مبتنی بر واژه‌نامه^{۵۱}. آنها نشان دادند که با در نظر گرفتن معیارهایی مانند عملکرد، کارایی و دقت، رویکرد یادگیری ماشین بهترین نتیجه را به همراه دارد. سانگ و همکاران [۵۴]، با معرفی مجموعه زبانی احتمالی و نظریه مربوطه، یک مدل نمایش متنی جدید را برای تحلیل احساسات متون کوتاه ارائه دادند. برخلاف تحلیل جملات و اسناد، تحلیل احساسات متون کوتاه به دلیل محدود بودن اطلاعات، مبهم بودن و تعدد معنای کلمات دشوار است. در این تحقیق، به منظور رفع این مشکلات، و نمایش ابهام کلمه، احساسات یک کلمه را به صورت اصطلاحات احتمالی زبانی^{۵۲} نشان دادند. سپس به کمک مجموع اصطلاحات احتمالی زبانی هر یک از کلمات،

42- Machine learning approach

43- N-gram Sentiment Analysis

44- Naive Bayes Method

45- Maximum Entropy Classifier

46- K-nearest Neighbor

47- Weighted K-nearest Neighbor

48- Multilingual Sentiment Analysis

49- Feature Driven Sentiment Analysis

50- Rule Based Approach

51- Lexical Based Approach

52- probabilistic linguistic terms

53- Chi-Square

54- Fusion

سریده‌هاران و همکاران [۵۹]، طبقه‌بندی احساسات با استفاده از جنگل تصادفی و روش گرادیان را ارائه و فرموله نمودند. مزیت این روش، دقت مناسب و چالش مهم آن پیچیدگی بالای روش برای طبقه‌بندی است.

جدول ۱، کارهای مرتبط در این زمینه را از منظر نوع روش، ترکیبی بودن مدل و استفاده از رابطه معنایی بین کلمات با هم مقایسه می‌کند. همان‌طور که این جدول نشان می‌دهد، تحقیقات کمی از رابطه معنایی بین کلمات استفاده نموده‌اند، درحالی‌که روابط معنایی بین کلمات در یک جمله می‌تواند تأثیر مثبتی در تعیین قطبیت در سطح جمله داشته باشد.

۳. روش پیشنهادی

از آنجایی‌که مسئله تشخیص نوع احساس کاربران یک مسئله طبقه‌بندی است، در این تحقیق روشی ترکیبی مبتنی بر دو تکنیک یادگیری عمیق RNN-GRU استفاده شده است. هدف نهایی روش پیشنهادی آن است که تا حد ممکن دقت

پیشنهاد دادند. در این معماری آنها اطلاعات متن، صدا و تصویر را استفاده نمودند و از سه ماژول جداگانه برای تحلیل هر یک از این سه دسته اطلاعات استفاده کردند. آنها در این پژوهش، از یک طبقه‌بندی ترکیبی از نوع ماشین بردار پشتیبان برای طبقه‌بندی احساس به ۴ گروه بسیار مثبت، مثبت، منفی و بسیار منفی استفاده نمودند. نتایج ارزیابی نشان می‌دهد روش پیشنهادی نسبت به روش‌های غیرهمجوشی دارای دقت بیشتر و این دقت در حدود ۳٪ بیشتر است. سعید و همکاران [۵۸]، یک روش یادگیری بانظارت برای طبقه‌بندی و تحلیل احساسات متون عربی ارائه نمودند. آنها به منظور استخراج ویژگی از متون عربی از روش N-gram و روش‌های کاهش بعد نظیر تجزیه و تحلیل مؤلفه اصلی^{۵۵} و LDA^{۵۶} استفاده نموده و برای طبقه‌بندی از درخت تصمیم استفاده نمودند. روش پیشنهادی با پنج مجموعه داده متن عربی نظرات از حوزه‌های مختلف و اندازه‌های مختلف آزمایش شده است. نتایج کلی نشان می‌دهد دقت روش پیشنهادی برای تحلیل احساس با انتخاب ویژگی در حدود ۲۴٪ افزایش داشته است.

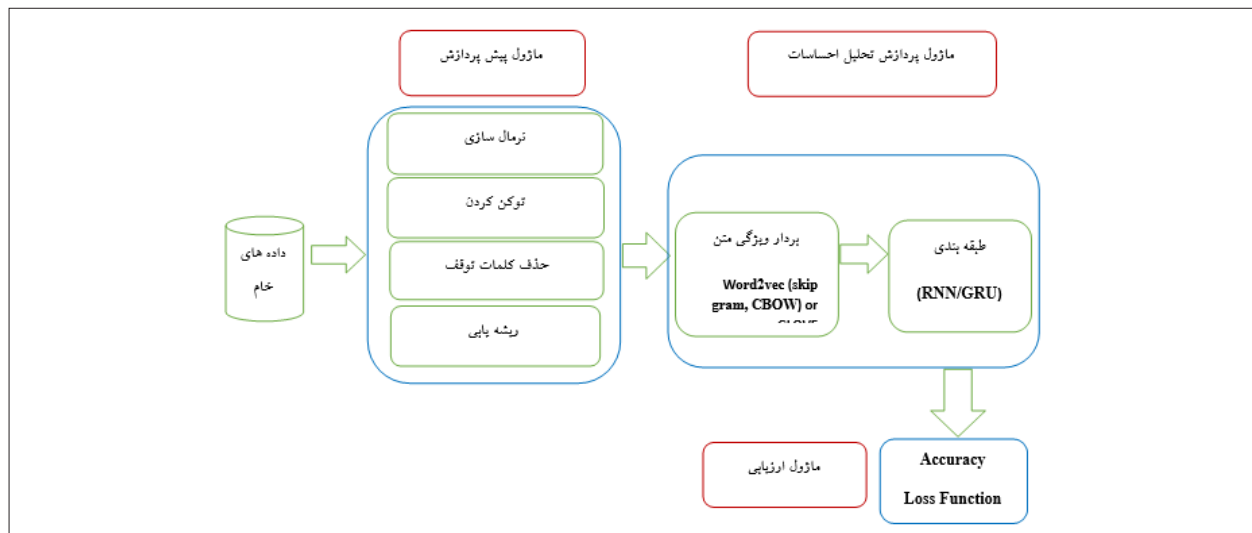
جدول ۱- مقایسه کارهای مرتبط

پژوهش	روش	سطح	مدل ترکیبی	رابطه معنایی بین کلمات	تعبیه‌گذاری
کیم و همکاران [۲۱]	شبکه‌های عصبی پیچشی دو کانالی	جمله			
هوانگ و همکاران نیز [۲۲]	بهبود مدل شبکه‌های عصبی هم‌آمیختگی	جنبه			
وو و همکاران [۲۳]	بهبود مدل شبکه‌های عصبی هم‌آمیختگی	جنبه		✓	
هیون و همکاران [۲۴]	شبکه‌های عصبی بازگشتی	جنبه		✓	
کلاچرنر و همکاران [۲۵]	شبکه‌های عصبی هم‌آمیختگی پویا	جمله		✓	
ین و همکاران [۲۶]	شبکه‌های عصبی هم‌آمیختگی واژگانی معنایی	جمله		✓	Word2vec
میشرا و همکاران [۲۸]	شبکه‌های عصبی هم‌آمیختگی	جمله			
بیان و همکاران [۲۹]	بهبود مدل شبکه‌های عصبی هم‌آمیختگی	جنبه		✓	
گوان و همکاران [۲۷]	بهبود مدل شبکه‌های عصبی هم‌آمیختگی	جمله			
زانگ و همکاران [۴۴]	شبکه عصبی هم‌آمیختگی مبتنی بر یادگیری منتقدانه	جمله			
زارماگامبوف و همکاران [۳۰]	شبکه‌های عصبی بازگشتی عمیق با مدل‌های درخت تصمیم	جمله	✓	✓	
موسی و همکاران [۳۲]	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند دوطرفه و یک مدل تفکیک‌کننده ساده	جمله	✓		
تنگ و همکاران [۳۳]	شبکه عصبی با حافظه کوتاه‌مدت بلند دوطرفه مبتنی بر مجموع وزنی ساده	جمله		✓	
وانگ و همکاران [۸]	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند	جنبه		✓	
کیان و همکاران [۳۴]	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند	جمله		✓	

55- Principal component analysis (PCA)

56- Latent Dirichlet allocation (LDA)

	✓		جنبه	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند دوطرفه	وی و همکاران [۴۷]
word2vec			جمله	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند	هوانگ و همکاران [۳۱]
			جمله	شبکه عصبی پیچشی مبتنی بر حافظه	. ماندولا و همکاران [۴۶]
			جمله	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند	داس و همکاران [۴۹]
	✓		جنبه	مدل پیش‌بینی بسته‌بندی مبتنی بر خودکدگذارها	رانگ و همکاران [۳۵]
			جمله	شبکه‌های عصبی هم‌آمیختگی و شبکه‌های عصبی بازگشتی	وانگ و همکارانش [۴۰]
word2vec	✓	✓	جمله	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند و شبکه‌های عصبی هم‌آمیختگی	گوگیلا و همکاران
			جمله	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند دوطرفه و شبکه‌های عصبی هم‌آمیختگی یک‌بعدی	چن و همکاران [۴۲]
word2vec	✓	✓	جملات دو قسمتی	شبکه‌های عصبی بازگشتی و شبکه‌های عصبی با حافظه کوتاه‌مدت بلند	عبدی و همکاران [۱۳]
word2vec	✓	✓	جمله	شبکه‌های عصبی با حافظه کوتاه‌مدت بلند	چاوش و همکاران [۴۳]
	✓	✓	جمله	شبکه عصبی هم‌آمیختگی و مدل حافظه کوتاه‌مدت استفاده	. هیکل و همکاران [۵۱]
			جمله	مجموعه زبانی احتمالی و نظریه مربوطه و ماشین بردار پشتیبان	سانگ و همکاران [۵۴]
Word2vec	✓	✓	جمله	مدل آماری و یادگیری بدون نظارت	حاجی‌پور و همکاران [۵۵]
			جمله	جنگل تصادفی و روش گرادیان	سریدهاران و همکاران [۵۹]
			چندسطحی	ماشین بردار پشتیبان	هودار و همکاران [۵۷]
			جمله	N-gram و روش‌های کاهش بعد و درخت تصمیم	سعید و همکاران [۵۸]
	✓	✓	جمله	BERT و شبکه‌های عصبی با حافظه کوتاه‌مدت بلند دوطرفه	رویز و همکاران [۵۰]
	✓	✓	جنبه	BERT و طبقه‌بندی جنگل تصادفی	ری و همکاران [۵۳]



شکل ۱: معماری روش پیشنهادی

- استفاده از الگوریتم یادگیری عمیق RNN-GRU به منظور تعیین قطبیت جملات
- ارزیابی و اعتبارسنجی روش پیشنهادی و مقایسه با روش‌های دیگر
- ۱-۳. پیش‌پردازش
- هدف این مرحله کاهش پیچیدگی محاسبات و تعیین قطبیت نظرات افزایش یابد. مطابق شکل ۱، روش پیشنهادی یک فرآیند چندمرحله‌ای به شرح زیر است:
- پیش‌پردازش متن: خروجی این مرحله مجموعه‌ای از کلمات استخراج شده از هر جمله است.
- تعبیه‌گذاری کلمات: استخراج ویژگی‌ها و یک ماتریس تعبیه کلمات که نشان‌دهنده رابطه معنایی بین آنها است.

نمی‌دهند، معمولاً از داده‌های متنی حذف می‌شوند. همچنین، در بسیاری از کاربردهای تحلیل احساسات، حذف لغات کم‌اهمیت که شاخصه متن نیستند، می‌تواند بدون از بین بردن معنا باعث بهبود دقت و سرعت الگوریتم‌های متن‌کاوی شود. به همین دلیل، این کلمات غالباً در مرحله پیش‌پردازش حذف می‌شوند. برای حذف ایست‌واژه‌ها، عموماً فهرستی از این کلمات از پیش تهیه می‌شود و سپس در صورت رخداد این کلمات در متن از سند حذف می‌شوند.

- ریشه‌یابی کلمات یکی از مهم‌ترین عملیات پیش‌پردازش متون در پردازش زبان‌های طبیعی است. منظور از ریشه صورت‌های گوناگون یک کلمه است که دارای ریشه‌های یکسانی هستند. در زبان انگلیسی، دو الگوریتم عمده‌ای که جهت بازگرداندن کلمات به شکل ریشه‌ای مورد استفاده قرار می‌گیرند، الگوریتم‌های Porter و Lancaster هستند.
- ریشه‌یابی و بن‌واژه‌یابی هر دو کار یکسان ولی به روش‌های مختلف انجام می‌دهند. با این حال، برخلاف عملیات ریشه‌یابی فرآیند بن‌واژه‌یابی وندهای کلمات را حذف نمی‌کند، بلکه از پایگاه‌های دانش لغوی جهت پیدا کردن ریشه صحیح کلمات استفاده می‌کند. همچنین، برخلاف ریشه‌یابی، بن‌واژه‌یابی شناسایی صحیح بخشی از گفتار و معنای یک کلمه در یک جمله و همچنین در محدوده اطراف آن جمله، جملات همسایه یا حتی کل سند می‌باشد.

۳-۲. نمایش برداری کلمات

در این مرحله به‌منظور نمایش بردار کلمات از تعبیه کلمات استفاده می‌شود تا کلمه هدف از بین کلمات محتوایی منبع پیش‌بینی شود. در این مرحله خروجی مرحله قبل را که یک ماتریس کلمات (هر سطر کلمات کلیدی یک جمله است) است، دریافت نموده و رابطه معنایی بین آنها مشخص می‌شود. شکل ۲-الف نمونه‌ای از تبدیل جملات متن را به بردار عددی و شکل ۲-ب نمونه‌ای از رابطه معنایی بین کلمات یک جمله را نشان می‌دهد.

پردازش در مراحل بعدی الگوریتم است. متن خام ابتدا به‌عنوان ورودی به مرحله پیش‌پردازش داده می‌شود. در این مرحله، هر سند به چند پاراگراف، هر پاراگراف به چند جمله و هر جمله به صورت مجزا به چند کلمه تجزیه می‌شود. در ادامه نرمال‌سازی متون و حذف کلماتی با بار معنایی کم و سپس ریشه‌یابی هر کلمه انجام می‌شود. خروجی به‌دست آمده از این فرآیند، یک مجموعه پالایش شده است که می‌تواند برای گام‌های بعدی یعنی تعبیه کلمات و آموزش الگوریتم‌های متن‌کاوی استفاده شود.

- هدف از نرمال‌سازی متن، تمیز و مرتب کردن متن و یکسان‌سازی نویسه‌ها با جایگزین کردن نویسه‌های استاندارد در متن ورودی است. در واقع، قبل از پردازش متون جهت استانداردسازی حروف و فاصله‌ها لازم است که پیش‌پردازش‌هایی از قبیل اصلاح نویسه‌ها، فاصله و نیم‌فاصله‌ها، وندها یا کلمات مرکب جدا نوشته شده، تبدیل کلمات محاوره‌ای و نویسه‌های حسی (ایموجی) به شکل استاندارد روی آن‌ها انجام شود. در این مرحله بایستی همه حروف متن با جایگزین شدن با معادل استاندارد خود، یکسان‌سازی شوند.

- هدف از تقطیع جملات و واژه‌ها، تشخیص جملات در متن ورودی یا به عبارتی جداسازی جملات ساده و مرکب، واژه‌ها و عبارات خاص از یکدیگر است. برای این کار از ابزار تشخیص‌دهنده جملات یعنی علائم تمام‌کننده جمله از قبیل: «.»، «!»، «؟»، «» به‌کارگیری برخی قواعد دستوری زبان و در نظر گرفتن حروف ربط یا برخی لغات آغازکننده جملات مرکب (از قبیل حروف ربط مانند اما، درحالی‌که، زیرا، سپس و غیره در زبان انگلیسی)، استفاده می‌شود.

- ایست‌واژه‌ها^۷، کلمات پرتکراری هستند که شامل عمومی‌ترین افعال، ضمائر، قیده‌ها، حروف ربط و حروف اضافه می‌باشند. از آنجایی‌که این کلمات بار معنایی خاصی ندارند و محتوای معنایی قابل‌توجهی را انتقال

	angry	bird	beautiful	crow	...	noisy	sweet	parrot	Ugly
about the bird	0	1	0	0		0	0	0	0
this bird is angry	1	1	0	0		0	0	0	0
this bird is angry and beautiful	1	1	1	0		0	0	0	0
.crow is a noisy and ugly bird	0	1	0	1		1	0	0	1
.parrot is a sweet-talking bird	0	1	0	0		0	1	1	0
الف									
	angry	bird	beautiful	crow	...	noisy	sweet	parrot	ugly
angry	1	0.7	0.6	0.69		0.8	0.1	0.3	0.45
bird	0.7	1	0.78	0.94		0.42	0.52	0.94	0.38
beautiful	0.6	0.78	1	0.89-		0.57	0.73	0.91	0.99-
crow	0.69	0.94	0.89-	1		0.91	0.56-	0.49	0.83
...									
noisy	0.8	0.42	0.57	0.91		1	0.95-	84/0-	0.4
sweet	0.1	0.52	0.73	0.56-		0.95-	1	0.91	0.12
Parrot	0.3	0.94	0.91	0.49		84/0-	0.91	1	0.37-
ب									

شکل ۲: بردار عددی کلمات و رابطه معنایی بین کلمات

و مدل Skip gram برعکس عمل می‌کند؛ یعنی با استفاده از کلمه هدف به کلمات محتوایی دست پیدا می‌کند. مدل GloVe که توسعه یافته Word2vec است، رویکردی برای اعمال قاعده مند و صریح روابط نحوی و معنایی بین کلمات است. GloVe برخلاف Word2vec به جای استفاده از یک پنجره برای تعریف زمینه محلی، یک ماتریس هم‌رخداد^{۶۱} را با استفاده از تحلیل آماری در کل مجموعه متن^{۶۲} ایجاد می‌کند تا یک مدل یادگیری ایجاد شود که منجر به تعبیه بهتر کلمات شود. این مدل از سایر مدل‌ها در قیاس کلمات، شباهت کلمات و وظایف تشخیص موجودیت نام‌گذاری شده بهتر عمل می‌کند.

۳-۳. پردازش

در این تحقیق از ترکیب RNN-GRU برای تعیین قطبیت استفاده شده تا عملکرد آن نسبت به RNN-LSTM [۱۳] و بقیه الگوریتم‌های ترکیبی یادگیری عمیق مقایسه شود. این مرحله شامل چهار لایه بردار ورودی، لایه RNN-

هدف آموزش در لایه تعبیه کلمات، بیشینه‌سازی احتمال شرطی مشاهده کلمه خروجی واقعی به‌ازای کلمات محتوایی ورودی، با توجه به وزن آنهاست. در این لایه، ویژگی‌های نحوی و معنایی مفید در مورد کلمات به دست می‌آید. از آنجایی که برای کارآمد بودن بردار تعبیه کلمات به لغت‌نامه‌ای با تعداد زیادی کلمه نیاز است و در صورت نداشتن تعداد لغات زیاد رابطه معنایی به‌خوبی پیدا نخواهد شد به همین علت بهتر است از روش‌های پیش آموزش دیده استفاده نمود. روش‌های از پیش آموزش دیده متنوعی مثل [۱۷] Word2vec، [۱۸] GloVe، [۲۰] FastText [BERT] [۱۹] وجود دارد که در این تحقیق از دو روش عمومی تعبیه کلمه در سطح جمله Word2vec و GloVe استفاده شده است تا عملکرد آنها نسبت به هم مقایسه شود. مدل تعبیه‌گذاری Word2vec شامل دو مدل CBOW^{۵۸} و Skip gram^{۵۹} است. در مدل CBOW، کلمه هدف^{۶۰} با جایگذاری کلمات محتوایی^{۶۰} پیش‌بینی می‌شود

61- Co-occurrence matrix
62- Corpus

58- Continuous Bag-of-Words model
59- Target
60- Context

گام‌های زمانی مختلف) دستخوش تغییر شوند حفظ کند. این نوع شبکه بسیار قدرتمند بوده و به واسطه سربار کمتر آنها نسبت به شبکه‌های عصبی با حافظه کوتاه مدت بلند و قدرت بیشتر آنها نسبت به شبکه‌های عصبی بازگشتی سنتی مورد استفاده گسترده قرار گرفته‌اند. در لایه الحاق، نمایش برداری استخراج شده از سلول شبکه عصبی واحد بازگشتی دروازه‌دار با ویژگی‌های احساسی و دانش زبانی (ویژگی سطح جمله) تقویت می‌شود تا یک نمایش برداری نهایی برای هر جمله ایجاد گردد. این بردار به لایه کاملاً متصل منتقل می‌شود تا با اعمال تابع «سیگموئید» بر روی آن قطبیت جمله مشخص شود. الگوریتم ۱، مراحل روش پیشنهادی را نشان می‌دهد.

Algorithm 1:

Input: set of sentences

Output: word embedding matrix

Let us denote $S = \{s_1, s_2, \dots, s_n\}$ as the set of sentences that Each s_i refers to a sentence.

Also each s_i is $s_i = \{w_1, w_2, \dots, w_n\}$ as the set of words in s_i that each w_i refers to a word

1- Preprocessing step:

$W = \text{NULL}$

For each s_i in S

//Preprocess s_i and make

a set of $w_i : \{w_1, w_2, \dots, w_n\}$

$s_i = \text{Tokenize}(s_i)$

$s_i = \text{removestopwords}(s_i)$

$s_i = \text{lowercaseconversion}(s_i)$

$w_i = \text{lemmatizeandrootextraction}(s_i)$

$W = W + w_i$

$W = \text{Padding}(W)$ /padding for maintaining fixed length

2- Word embedding step

Wematrix = Apply the word embedding vector

to W matrix

$W2v = \text{Word2vec embedding}(wematrix)$

$Ge = \text{GloVe embedding}(wematrix)$

3- Processing step:

// let us denote $DL1$ as the first classifier and $DL2$ as the second classifier

Output: set of classification results: results =

GRU، لایه الحاق و لایه با اتصالات کامل^{۶۳} است. در بخش بردار ورودی ابتدا جملات از طریق مرحله پیش‌پردازش به جملات استاندارد تبدیل شده‌اند و تنها حاوی اطلاعات مهم و رابطه معنایی بین آنها در زمینه تحلیل احساسات هستند. در نتیجه ترکیب تعبیه سطح کلمات، احساسات و ویژگی‌های سطح کلمه به لایه RNN-GRU ارسال می‌گردد. از آنجایی که اطلاعات ترتیبی کلمات و روابط معنایی بین آنها تأثیر مهمی روی عملکرد دسته‌بندی احساسات دارد، شبکه عصبی بازگشتی در بعضی موارد با مشکل مواجه می‌شود. به عنوان مثال می‌تواند قطبیت کلمات منفی مثل not و bad را به خوبی تشخیص دهد؛ اما عبارتی مثل not bad که ترکیبی از دو کلمه قبلی هست را نمی‌تواند به خوبی تعیین قطبیت نماید. از طرفی طول جملاتی که این شبکه می‌تواند پردازش کند محدود است و یادگیری کلماتی که به هم وابسته بوده؛ ولی از هم در یک جمله فاصله زیادی دارند مشکل خواهد بود. به عبارتی یکی از مشکلات اصلی در شبکه عصبی بازگشتی سنتی این است که در این شبکه محتویات گام زمانی فعلی همیشه با یک مقدار جدید از ورودی و حالت قبلی جایگزین می‌شوند و این‌طور اساساً قابلیت حفظ یک ویژگی از چندین گام زمانی خیلی عقب‌تر ممکن نیست. به همین علت در این تحقیق خروجی شبکه عصبی بازگشتی به شبکه عصبی واحد بازگشتی دروازه‌دار داده می‌شود تا این مشکل برطرف شود. در این شبکه از یک واحد حافظه استفاده می‌شود تا حالت را در مدت زمان طولانی حفظ کند. شبکه عصبی واحد بازگشتی دروازه‌دار برای رسیدن به این هدف از دو دروازه به روزرسانی و دروازه بازنشانی استفاده می‌کند. این دو دروازه در اصل دو بردار هستند که با استفاده از آنها تصمیم گرفته می‌شود چه اطلاعاتی به خروجی منتقل شده و چه اطلاعاتی منتقل نشود. نکته خاص درباره این دروازه‌ها این است که این دروازه‌ها را می‌توان آموزش داد تا این‌طور اطلاعات مربوط به گام‌های زمانی بسیار قبل را بدون آنکه در حین گذر زمان (طی

گرفته شده است.

ورودی لایه تعبیه، داده glove و word2vec با طول کلمات ۱۰۰۰۰ هست. این داده‌ها بایستی به یک ماتریس وزن داده شوند که برای هر کلمه یک سطر داشته باشد و به تعداد ابعاد هم ستون داشته باشد. این ماتریس به‌عنوان ماتریس وزن به مدل‌های یادگیری عمیق در لایه اول مرحله پردازش داده می‌شود تا شبکه از یک مدل از پیش آموزش‌دیده شده استفاده کند.

در مرحله پردازش مدل‌های ترکیبی زیر پیاده‌سازی و با هم مقایسه شده‌اند:

۱. لایه تعبیه‌گذاری از Word2vec استفاده کرده باشد، لایه دوم شبکه عصبی بازگشتی و لایه سوم شبکه عصبی با حافظه کوتاه‌مدت بلند [۱۳]
۲. لایه تعبیه‌گذاری از GloVe استفاده کرده باشد، لایه دوم شبکه عصبی بازگشتی و لایه سوم شبکه عصبی واحد بازگشتی دروازه‌دار (روش پیشنهادی)
۳. لایه تعبیه‌گذاری از GloVe استفاده کرده باشد، لایه دوم شبکه عصبی بازگشتی و لایه سوم شبکه عصبی با حافظه کوتاه‌مدت بلند
۴. لایه تعبیه‌گذاری از Word2vec استفاده کرده باشد، لایه دوم شبکه عصبی بازگشتی و لایه سوم شبکه عصبی واحد بازگشتی دروازه‌دار (روش پیشنهادی)
۵. لایه تعبیه‌گذاری از Word2vec استفاده کرده باشد، لایه دوم شبکه عصبی بازگشتی
۶. لایه تعبیه‌گذاری از Word2vec استفاده کرده باشد، لایه دوم شبکه عصبی با حافظه کوتاه‌مدت بلند
۷. لایه تعبیه‌گذاری از Word2vec استفاده کرده باشد، لایه دوم شبکه عصبی واحد بازگشتی دروازه‌دار
۸. لایه تعبیه‌گذاری از GloVe استفاده کرده باشد، لایه دوم شبکه عصبی بازگشتی
۹. لایه تعبیه‌گذاری از GloVe استفاده کرده باشد، لایه

{sentence, sentiment} and
Accuracy

```
(traindataset, testdataset) = devidedataset(W)
DL1 = Create(classifier1)
RDL1 = train(traindataset, DL1, p) //Set of
the first algorithm results, obtained after per-
forming Deep learning algorithm DL1 classifica-
tion;
P: probability of classification.
```

```
DL2 = Create(classifier2)
RDL2 = train(RDL1, DL2, v) //Set of the first
algorithm results, obtained after performing
Deep learning algorithm DL2 classification;
v: DL2 result value: contains "positive", "nega-
tive" or "neutral" sentiment.
```

۴. ارزیابی روش پیشنهادی

در این بخش روش پیشنهادی ارزیابی شده و نتایج آن نمایش داده می‌شود. برای انجام ارزیابی از زبان برنامه‌نویسی پایتون بر روی یک رایانه همراه دارای پردازنده intel i7 3210M با ۳۲ گیگابایت حافظه اصلی و حافظه جانبی SSD استفاده شده است. در این تحقیق، دو مجموعه داده توییت‌های خطوط هوایی^{۶۴} و نظرات فیلم^{۶۵} برای ارزیابی الگوریتم‌های پیشنهادی به کار گرفته شدند. مجموعه داده نظرات فیلم حاوی ۵۰۰۰۰ نظر در رابطه با نظرات فیلم‌ها است که هر نظر حاوی برچسب‌های مثبت یا منفی است. مجموعه داده توییت‌های خطوط هوایی نیز حاوی یک میلیون و ۶۰۰ هزار نظر با ۳ برچسب مثبت، منفی و خنثی هستند. پیش‌پردازش نظرات این مجموعه داده‌ها مطابق بخش ۳ انجام شد. بعد از آماده‌سازی اولیه داده‌ها، ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای آزمایش در نظر گرفته شدند. در ادامه از آنجایی که طول جملات متفاوت است از تابع padding استفاده شده است تا طول جملات با اضافه‌کردن نویسه خاص به ابتدا یا انتهای جمله یکسان شود. حداکثر طول جمله، ۵۰ کلمه در نظر

64- <https://www.kaggle.com/datasets/crowdfLOWER/twitter-airline-sentiment>

65- <https://www.kaggle.com/datasets/lakshmi25npathi/imdb-dataset-of-50k-movie-reviews>

۷۸٪ است. مطابق با شکل c-۳ در صورت استفاده از لایه تعبیه word2vec به همراه لایه شبکه عصبی واحد بازگشتی دروازه‌دار، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۹۵٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۹٪ است. مطابق با شکل d-۳، در صورت استفاده از word2vec به همراه لایه شبکه عصبی با حافظه کوتاه‌مدت بلند، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۹۶٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۶٪ است. مطابق با شکل e-۳، در صورت استفاده از word2vec به همراه لایه شبکه عصبی بازگشتی، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۸۵٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۵٪ است.

ارزیابی روش‌ها مبتنی بر تعبیه گذاری GloVe

مطابق با شکل a-۴، در صورت استفاده از لایه تعبیه GloVe به همراه دو لایه شبکه عصبی بازگشتی و شبکه عصبی واحد بازگشتی دروازه‌دار، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۹۸٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۷٪ است. مطابق با شکل b-۴، در صورت استفاده از لایه تعبیه GloVe به همراه دو لایه شبکه عصبی بازگشتی و شبکه عصبی با حافظه کوتاه‌مدت بلند، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۹۵٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۵٪ است. مطابق با شکل c-۴، در صورت استفاده از لایه تعبیه GloVe به همراه دو لایه شبکه عصبی واحد بازگشتی دروازه‌دار، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۹۸٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۸٪ است. مطابق با شکل d-۴، در صورت استفاده از لایه تعبیه GloVe به همراه دو لایه شبکه عصبی با حافظه کوتاه‌مدت بلند، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۹۱٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۶٪ است. مطابق با شکل e-۴، در صورت استفاده از لایه تعبیه GloVe به همراه دو لایه شبکه عصبی بازگشتی، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۹۶٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۵٪ است.

دوم شبکه عصبی با حافظه کوتاه‌مدت بلند ۱۰. لایه تعبیه‌گذاری از GloVe استفاده کرده باشد، لایه دوم شبکه عصبی واحد بازگشتی دروازه‌دار در لایه پردازش در مدل یادگیری عمیق اول تعداد نرون‌ها به اندازه طول جمله یعنی ۵۰ در نظر گرفته شده است و تابع فعال‌سازی آن Relu در نظر گرفته شده است و در لایه بعدی تعداد نرون‌های ورودی آن ۳۲ و تابع فعال‌سازی آن Relu در نظر گرفته شده است. تعداد نرون‌ها در این لایه به خاطر مواجه نشدن با بیش‌برازش^{۶۶} ۳۲ انتخاب شده است. در ادامه یک لایه متراکم^{۶۷} با تابع فعالیت softmax تعریف شده است تا خروجی این لایه که ۳ نرون هست را تعریف کند. این ۳ نرون خروجی همان قطبیت جمله است.

جهت تعیین عملکرد روش پیشنهادی به دلیل متوازن بودن داده‌ها از نظر برچسب از معیار صحت^{۶۸} و تابع زیان^{۶۹} آنتروپی متقابل^{۷۰} استفاده شده است.

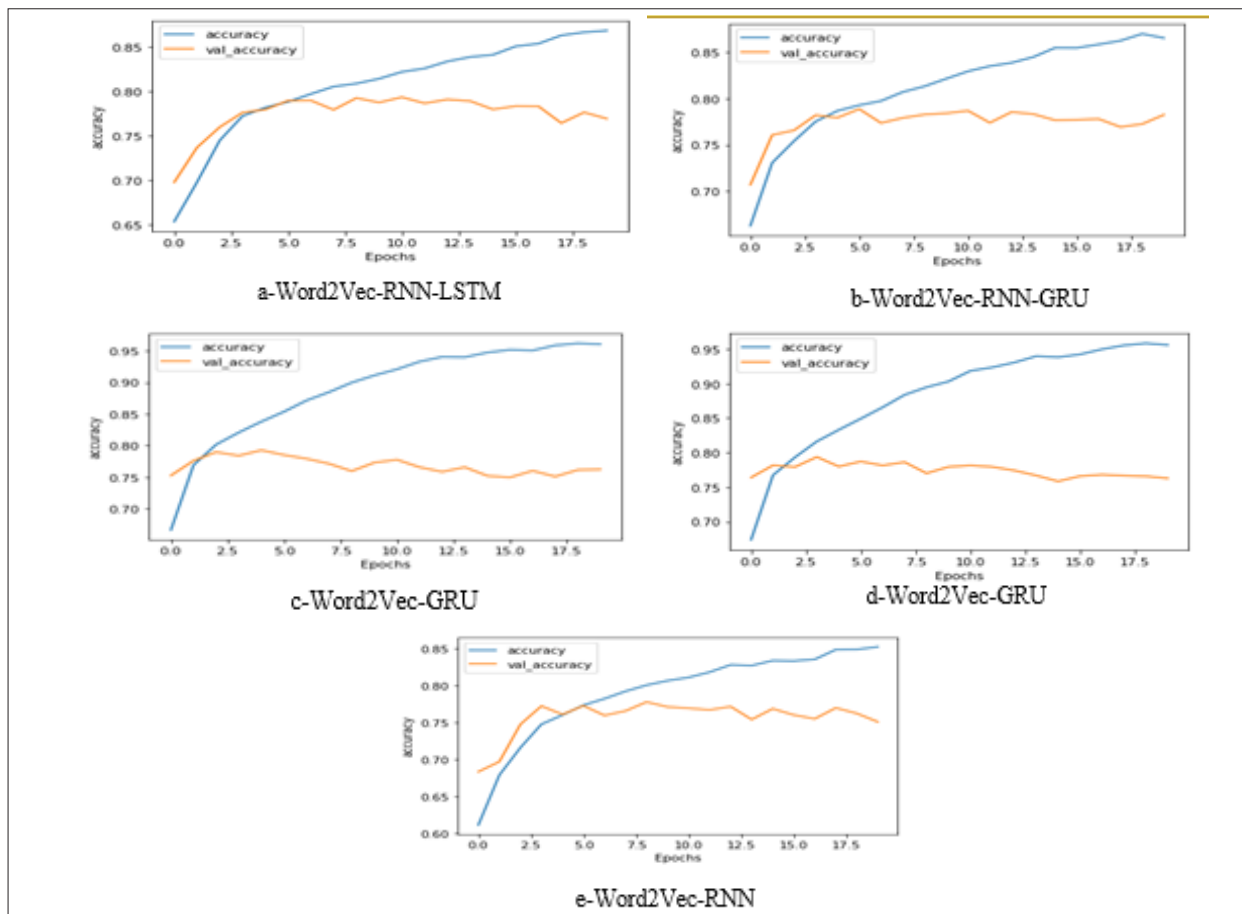
۴-۱. مقایسه روش‌ها بر روی مجموعه داده توییت‌های هواپیمایی

در این بخش روش‌های مطرح شده بر روی مجموعه داده tweet.csv اجرا شده و نتایج زیر را تولید نمودند.

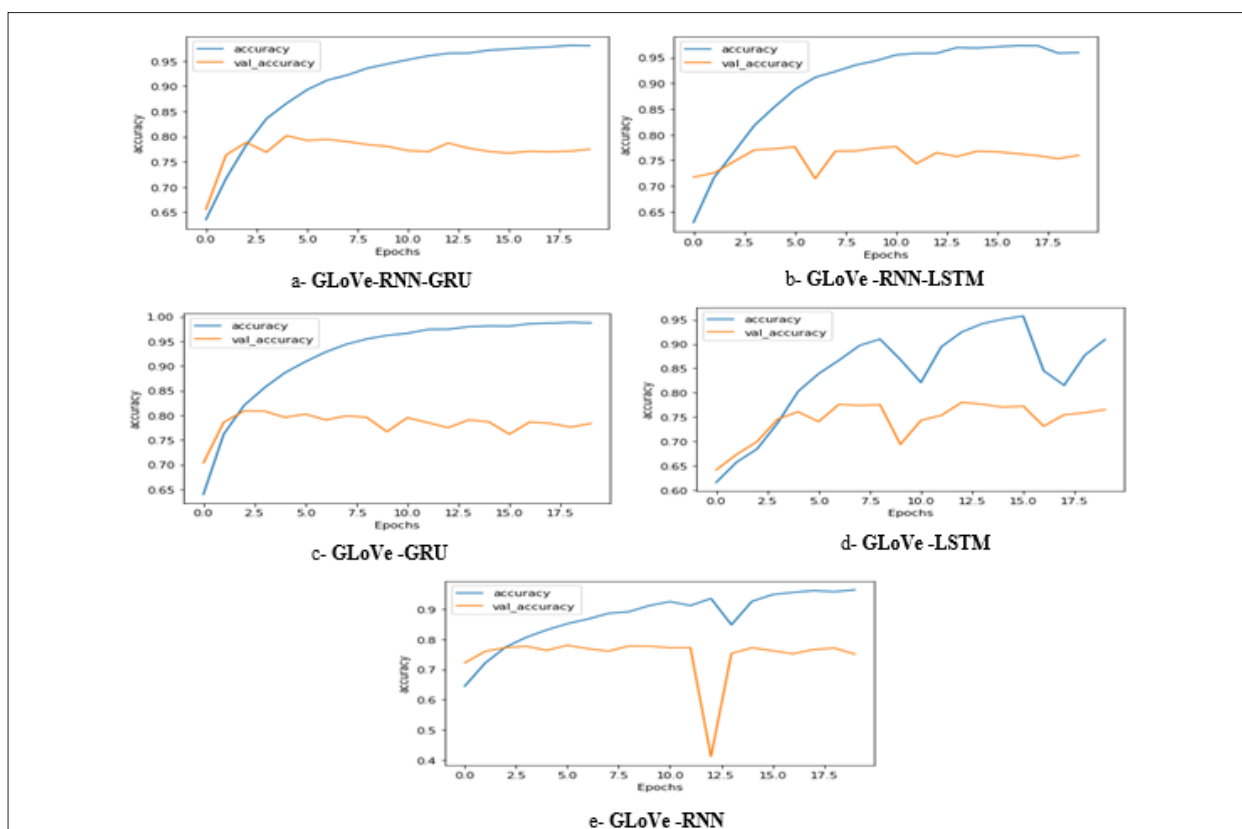
ارزیابی روش‌ها مبتنی بر تعبیه‌گذاری Word2vec

مطابق با شکل a-۳، در صورت استفاده از لایه تعبیه word2vec به همراه دو لایه شبکه عصبی بازگشتی و سپس شبکه عصبی با حافظه کوتاه‌مدت بلند [۱۳]، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۸۵٪ و بر روی داده‌های اعتبارسنجی تقریباً ۷۸٪ است. مطابق با شکل b-۳، در صورت استفاده از لایه تعبیه word2vec به همراه دو لایه شبکه عصبی بازگشتی و سپس شبکه عصبی واحد بازگشتی دروازه‌دار، دقت الگوریتم بر روی داده‌های آموزش تقریباً ۸۷٪ و بر روی داده‌های اعتبارسنجی تقریباً

66- overfit
67- Dense
68- Accuracy
69- Loss Function
70- Cross-entropy



شکل ۳: مقایسه روش‌ها بر روی مجموعه‌داده‌های توییت‌های هواپیمایی در صورت استفاده از لایه تعبیه Word2vec



شکل ۴: مقایسه روش‌ها بر روی مجموعه‌داده‌های توییت‌های هواپیمایی در صورت استفاده از لایه تعبیه GloVe

این تحقیق حاصل شد نشان می‌دهد که روش پیشنهادی نسبت به روش‌های دیگر، دقت طبقه‌بندی کلمات را بهبود می‌بخشد. همچنین، با اجرای روش پیشنهادی روی مجموعه داده توییت‌های هواپیمایی و نظرات فیلم به منظور تشخیص سه قطبیت مثبت، منفی و خنثی در صورت استفاده از تعبیه‌گذاری Word2vec به دقت ۰/۷۸ و در صورت استفاده از تعبیه‌گذاری Glove به دقت ۰/۷۷ دست یافته است.

با ارزیابی و مقایسه روش پیشنهادی با روش‌های دیگر می‌توان به نتایج زیر دست یافت:

- شبکه عصبی RNN-GRU در تحلیل/طبقه‌بندی احساسات سطح جمله دقت را نسبت به شبکه‌های عصبی سنتی عمیق بهبود بخشید.

- شبکه عصبی RNN-GRU در تحلیل/طبقه‌بندی احساسات سطح جمله در صورت استفاده از تعبیه‌گذاری کلمات Word2vec نسبت به Glove دقت بیشتری دارد.

- شبکه عصبی بازگشتی در تحلیل/طبقه‌بندی احساسات سطح جمله در هر دو حالت استفاده از تعبیه‌گذاری کلمات Word2vec و Glove نسبت به بقیه روش‌ها پایین‌ترین دقت را داشتند.

- استفاده از شبکه عصبی واحد بازگشتی دروازه‌دار در صورت استفاده از تعبیه‌گذاری کلمات Word2vec و شبکه عصبی با حافظه کوتاه‌مدت بلند در هر دو حالت استفاده از تعبیه‌گذاری کلمات Word2vec و Glove دقت مشابهی داشتند در مقایسه با شبکه عصبی بازگشتی دقت بالاتری داشتند
- استفاده از شبکه عصبی واحد بازگشتی دروازه‌دار در صورت استفاده از تعبیه‌گذاری کلمات Glove دقتی مشابه با روش پیشنهادی در صورت استفاده از تعبیه‌گذاری کلمات Word2vec دارد.

در ادامه این پژوهش می‌توان روش پیشنهادی را بر روی نظرات فارسی اعمال نمود. همچنین می‌توان درجه‌بندی قطبیت احساسات به دسته‌های بیشتر (خیلی بد، بد، خنثی، خوب و خیلی خوب) به منظور نشان دادن اهمیت

۴-۱. مقایسه کلی روش‌ها بر روی دو مجموعه داده

در این بخش روش پیشنهادی با شبکه عصبی بازگشتی، شبکه عصبی با حافظه کوتاه‌مدت بلند، شبکه عصبی واحد بازگشتی دروازه‌دار و ترکیب اینها در دو حالت تعبیه‌گذاری Word2vec و Glove بر روی دو مجموعه داده توییت‌های خطوط هوایی و نظرات فیلم‌ها انجام شده است. جدول ۲ این ارزیابی را نشان می‌دهد.

همان‌طور که جدول نشان می‌دهد روش پیشنهادی در حالت تعبیه‌گذاری Word2vec از همه روش‌ها دقت بالاتری دارد؛ ولی با استفاده از تعبیه‌گذاری Glove بهبود قابل توجهی نداشته است.

جدول ۲: مقایسه روش‌ها بر روی دو مجموعه داده توییت‌های هواپیمایی و نظرات فیلم‌ها

	Airline Tweet		IMDB	
	Loss	accuracy	Loss	Accuracy
W-RNN-LSTM [13]	0.67	0.77	1.3	0.5
W-RNN-GRU (proposed)	0.58	0.78	0.4	0.89
W-GRU	1.3	0.76	0.5	0.88
W-LSTM	1.19	0.76	0.3	0.88
G-RNN-GRU (proposed)	1.19	0.77	0.4	0.86
G-RNN-LSTM	1	0.75	0.69	0.51
Glove-GRU	1.17	0.78	0.87	0.84
G-LSTM	0.77	0.76	0.6	0.85
G-RNN	1.3	0.75	0.6	0.57
W-RNN	0.7	0.75	0.6	0.63

۵. نتیجه‌گیری

رشد وب و گسترش شبکه‌های اجتماعی منجر به تولید حجم عظیمی از داده‌ها شده است. تحلیل این داده‌ها در زمینه‌های مختلف، می‌تواند بسیار مفید باشد. بر همین اساس، تحلیل احساسات به منظور کشف اطلاعات ارزشمند بسیار حائز اهمیت است. در این پژوهش برای بهبود دقت در تعیین قطبیت نظرات مبتنی بر متن از ترکیب دو الگوریتم یادگیری عمیق شبکه عصبی بازگشتی و شبکه عصبی واحد بازگشتی دروازه‌دار به همراه دو روش تعبیه‌گذاری Word2vec و Glove استفاده شده است. نتایجی که در

- deep learning for sentiment analysis across languages: A survey. *Neurocomputing*, 531, 195-216, 2023.
15. Otter, D. W., Medina, J. R., & Kalita, J. K. A survey of the usages of deep learning for natural language processing. *IEEE transactions on neural networks and learning systems*, 32(2), 604-624, 2020.
 16. Almeida, F., & Xexéo, G. Word embeddings: A survey. *arXiv preprint arXiv:1901.09069*, 2019.
 17. Church, K. W. Word2Vec. *Natural Language Engineering*, 23(1), 155-162, 2017.
 18. Pennington, J., Socher, R., & Manning, C. D. Glove: Global vectors for word representation, *The 2014 conference on empirical methods in natural language processing (EMNLP)*, 1532-1543, 2014.
 19. Tanaka, H., Shinnou, H., Cao, R., Bai, J., & Ma, W. Document classification by word embeddings of bert. In *Computational Linguistics: 16th International Conference of The Pacific Association for Computational Linguistics*, 145-154, 2020.
 20. Gaikwad, V., & Haribhakta, Y. Adaptive glove and fasttext model for hindi word embeddings. *The 7th ACM IKDD CoDS and 25th COMAD*, 175-179, 2020.
 21. Kim Y. Convolutional neural networks for sentence classification. *The Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, 1746-1751, 2014.
 22. Huang. B. and Carley .K., Parameterized convolutional neural networks for aspect level sentiment classification, *The Conference on Empirical Methods in Natural Language Processing*, 1091-1096, 2018.
 23. Wu C, Xiong Q, Gao M, Li Q, Yu Y, Wang K. A relative position attention network for aspect-based sentiment analysis. *Knowledge and Information Systems*. 1-5, 2020.
 24. Hyun D, Park C, Yang MC, Song I, Lee JT, Yu H. Target-aware convolutional neural network for target-level sentiment analysis. *Information Sciences*. Vol. 491, 166-178, 2019.
 25. Kalchbrenner N, Grefenstette E, Blunsom P. A convolutional neural network for modeling sentences. *The 52nd Annual Meeting of the Association for Computational Linguistics*, 655-665, 2014.
 26. Yin, R., Li, P., & Wang, B. Sentiment lexical-augmented convolutional neural networks for sentiment analysis. *IEEE Second International Conference on Data Science in Cyberspace (DSC)*, 630-635, 2017.
 27. Guan Z, Chen L, Zhao W, Zheng Y, Tan S, and Cai D. Weakly-supervised deep learning for customer review sentiment classification. *The International Joint Conference on Artificial Intelligence (IJCAI)*, 3719-3725, 2016.
 28. Mishra A, Dey K, Bhattacharyya P. Learning cognitive features from gaze data for sentiment and sarcasm classification using convolutional neural network. *The 55th Annual Meeting of the Association for Computational Linguistics*, 377-387, 2017.
 29. Bian, Y., Ye, R., Zhang, J., & Yan, X. Customer preference identification from hotel online reviews: A neural network based fine-grained sentiment analysis. *Computers & Indus-*

نظر را در نظر گرفت. در نهایت استفاده از طبقه‌بندهای جدید مثل شبکه‌های کپسوله در ترکیب با روش‌هایی استفاده شده در این پژوهش و استفاده از روش پیشنهادی در تحلیل احساسات مبتنی بر جنبه را می‌توان از کارهای آتی نام برد.

مراجع

1. Alshuwaier, F., Areshey, A., & Poon, J. Applications and Enhancement of Document-Based Sentiment Analysis in Deep Learning Methods: Systematic Literature Review. *Intelligent Systems with Applications*, 2022.
2. Appel. O., Chiclanaa. F., Carter. J., Fujita. H., Successes and challenges in developing a hybrid approach to sentiment analysis, *Appl. Intell.* vol.48, 1176-1188, 2018.
3. Cambria. E., Affective computing and sentiment analysis, *IEEE Intell. Syst.* Vol. 31, 102-107, 2016.
4. Gupte, A., Joshi, S., Gadgul, P., Kadam, A., & Gupte, A. Comparative study of classification algorithms used in sentiment analysis. *International Journal of Computer Science and Information Technologies*, 5(5), 6261-6264, 2014.
5. Devika, M. D., Sunitha, C., & Ganesh, A. Sentiment analysis: a comparative study on different approaches. *Computer Science Procedia*, 87, 44-49, 2016.
6. Schmidhuber, J. Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117, 2015.
7. Wang. B., Liakata .M., Zubiaga. A., and Procter.R., Tdparse: Multi-target-specific sentiment recognition on twitter, *The 15th Conference of the European Chapter of the Association for Computational Linguistics*, Vol.1, 483-493, 2017.
8. Wang, Y., Huang, M., Zhao, L., & Zhu, X., Attention-based LSTM for Aspect-level Sentiment Classification, *The Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 606-615, 2016.
9. Wang, J., Sun, C., Li, S., Wang, J., Si, L., Zhang, M., ... & Zhou, G. Human-like decision making: Document-level aspect sentiment classification via hierarchical reinforcement learning. *arXiv preprint arXiv:1910.09260*, 2019.
10. Wu C, Xiong Q, Gao M, Li Q, Yu Y, Wang K. A relative position attention network for aspect-based sentiment analysis. *Knowledge and Information Systems*. 1-5, 2020.
11. Shuang K, Yang Q, Loo J, Li R, Gu M. Feature distillation network for aspect-based sentiment analysis. *Information Fusion*. Vol.61, 13-23, 2020.
12. Tay, Y., Tuan, L. A., & Hui, S. C., Dyadic Memory Networks for Aspect-based Sentiment Analysis. *The ACM Conference on Information and Knowledge Management*, 107-116, 2017.
13. Abdi A, Shamsuddin SM, Hasan S, Piran J. Deep learning-based sentiment classification of evaluative text based on Multi-feature fusion. *Information Processing & Management*, Vol. 56(4), 1245-59, 2019.
14. Mercha, E. M., & Benbrahim, H. Machine learning and

- for optimizing convolutional neural networks with rules. *Neurocomputing*, 2019. 356: p. 21-30.
45. Li, L., Goh, T. T., & Jin, D. (2020). How textual quality of online reviews affect classification performance: a case of deep learning sentiment analysis. *Neural Computing and Applications*, 32(9), 4387-4415.
 46. Mandhula, T., Pabboju, S., & Gugulotu, N. (2019). Predicting the customer's opinion on amazon products using selective memory architecture-based convolutional neural network. *The Journal of Supercomputing*, 1-25.
 47. Wei, J., et al., BiLSTM with multi-polarity orthogonal attention for implicit sentiment analysis. *Neurocomputing*, 2020. 383: p. 165-173.
 48. Dashtipour, K., et al., A hybrid Persian sentiment analysis framework: Integrating dependency grammar based rules and deep neural networks. *Neurocomputing*, 2020. 380: p. 1-10.
 49. Das, S., Das, D., & Kolya, A. K. (2020). Sentiment classification with GST tweet data on LSTM based on polarity-popularity model. *Sādhanā*, 45, 1-17.
 50. Colón-Ruiz, C. and I. Segura-Bedmar, Comparing deep learning architectures for sentiment analysis on drug reviews. *Journal of Biomedical Informatics*, 2020. 110: p. 103539.
 51. Heikal, M., M. Torki, and N. El-Makky, Sentiment analysis of Arabic tweets using deep learning. *Procedia Computer Science*, 2018. 142: p. 114-122.
 52. Chiarello, F., A. Bonaccorsi, and G. Fantoni, Technical sentiment analysis. Measuring advantages and drawbacks of new products using social media. *Computers in Industry*, 2020. 123: p. 103299.
 53. Ray, B., A. Garain, and R. Sarkar, An ensemble-based hotel recommender system using sentiment analysis and aspect categorization of hotel reviews. *Applied Soft Computing*, 2021. 98: p. 106935.
 54. Song, C., et al., SACPC: A framework based on probabilistic linguistic terms for short text sentiment analysis. *Knowledge-Based Systems*, 2020. 194: p. 105572.
 55. Hajipour, O., Sadidpour, S. S., Automatic extraction of keywords from Persian short texts using word2vec., *Electronic and cyber defense journal*, 2020, 8(2), p. 105-114 (in persian).
 56. Wang, Z., & Lin, Z. (2020). Optimal feature selection for learning-based algorithms for sentiment classification. *Cognitive Computation*, 12(1), 238-248.
 57. Huddar, M. G., Sannakki, S. S., & Rajpurohit, V. S. (2019). Multi-level context extraction and attention-based contextual inter-modal fusion for multimodal sentiment analysis and emotion classification. *International Journal of Multimedia Information Retrieval*, 1-10.
 58. Saeed, R. M., Rady, S., & Gharib, T. F. (2021). Optimizing Sentiment Classification for Arabic Opinion Texts. *Cognitive Computation*, 13(1), 164-178.
 59. Sridharan, K., & Komarasamy, G. (2020). Sentiment classification using harmony random forest and harmony gradient boosting machine. *Soft Computing*, 24(10), 7451-7458.
 - trial Engineering, 172, 2022.
 30. Zharmagambetov AS, Pak AA. Sentiment analysis of a document using deep learning approach and decision trees. In *Twelve international conference on electronics computer and computation (ICECCO)*, 1-4, 2015.
 31. Huang M, Qian Q, Zhu X. Encoding syntactic knowledge in neural networks for sentiment classification. *ACM Transactions on Information Systems (TOIS)*. 35(3), 1-27, 2017.
 32. Mousa A, Schuller B. Contextual bidirectional long short-term memory recurrent neural network language models: a generative approach to sentiment analysis. *The 15th Conference of the European Chapter of the Association for Computational Linguistics, Valencia*, 1023-1032, 2017.
 33. Teng Z, Vo DT, Zhang Y. Context-sensitive lexicon features for neural sentiment analysis. *The conference on empirical methods in natural language processing*, 1629-1638, 2016.
 34. Qian Q, Huang M, Lei J, and Zhu X. Linguistically regularized LSTM for sentiment classification. *The Annual Meeting of the Association for Computational Linguistics*, 1365-1374, 2017.
 35. Rong W, Nie Y, Ouyang Y, et al. Auto-encoder based bagging architecture for sentiment analysis. *J Visual Lang Comput*, Vol, 25, 840-849, 2014.
 36. Jin Y, Zhang H, Du D L. Improving deep belief networks via delta rule for sentiment classification. *The 28th International Conference on Tools with Artificial Intelligence*, 410-414, 2016.
 37. Jin Y, Zhang H, Du D L. Incorporating positional information into deep belief networks for sentiment classification, *Industrial Conference on Data Mining*, pp.1-15, 2017.
 38. Vlachostergiou A, Caridakis G, Mylonas P, et al. Learning representations of natural language texts with generative adversarial networks at document, sentence, and aspect level. *Algorithms*, Vol.11: 164, 2018.
 39. Socher R, Pennington J, Huang EH, Ng AY, Manning CD. Semi-supervised recursive autoencoders for predicting sentiment distributions. *The conference on empirical methods in natural language processing*, 151-161, 2011.
 40. Wang X, Jiang W, Luo Z. Combination of convolutional and recurrent neural network for sentiment analysis of short texts. *The 26th international conference on computational linguistics: Technical papers*, 2428-2437, 2016.
 41. Guggilla C, Miller T, Gurevych I. CNN-and LSTM-based claim classification in online user comments. *The 26th International Conference on Computational Linguistics: Technical Papers*, 2740-2751, 2016.
 42. Chen T, Xu R, He Y, Wang X. Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN. *Expert Systems with Applications*. Vol. 72, 221-30, 2017.
 43. Chavosh, N., Emadi, S, Improving Sentence Polarity Determination in Sentiment Analysis based on RNN and LSTM Deep Learning Algorithm, *Applied and Basic Machine Intelligence Research*, 1(1), 108-115, 2022.
 44. Zhang, B., et al., Sentiment analysis through critic learning