

اعتقادکاوی متون فارسی بر اساس یادگیری عمیق با تفکیک احساس-کلمه

حسین علی کرمی^{*}، امیر مسعود بیدگلی^{(نویسنده مسئول) **}، حمید حاج سید جوادی^{***}

^{*} گروه مهندسی کامپیوتر، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران.

^{**} گروه مهندسی کامپیوتر، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران.

^{***} گروه ریاضی و علوم کامپیوتر، دانشگاه شاهد، تهران، ایران.

چکیده

اعتقادکاوی یا طبقه بندی متون بر اساس احساس و عقیده کاربران در وسایت‌ها و رسانه‌های اجتماعی به مردم، شرکت‌ها و سازمان‌ها کمک می‌کند تا بتوانند تصمیم‌گیری‌های مهم را انجام دهند. اعتقادکاوی شامل یک سیستم برای تحلیل عقاید و احساسات مردم درباره یک موجودیت مانند محصولات، افراد، سازمان‌ها با توجه به نظرات، پیام‌ها و توبیت‌های کاربران در رسانه‌های اجتماعی می‌باشد.

در این مقاله اعتقادکاوی متون فارسی بر اساس پیام‌ها، نظرات و توبیت‌های کاربران در رسانه اجتماعی با استفاده از دو روش یادگیری عمیق **CNN**، **LSTM** با در نظر گرفتن شدت احساس کلمات و دیدگاه کاربران، در دو قطب مثبت و منفی با بازه $-2 \text{ و } +2$ طبقه بندی شده‌اند. در روش پیشنهادی ابتدا فرآیند پیش‌پردازش داده‌ها بر اساس تبدیل کاراکتر به عدد، حذف لیست واژه‌های اضافی و تحلیل چند واژه‌ای انجام می‌شود، در مرحله دوم جهت اعتقادکاوی و طبقه‌بندی متون فارسی از الگوریتم‌های یادگیری عمیق **LSTM** و **CNN** با تفکیک احساس بر روی کلمات (**WSD**) استفاده می‌شود تا شدت احساسات را با توجه به کلمات تشخیص دهد، در مرحله سوم دیدگاه کاربران با طبقه بندی متون در چهار دسته سیاسی، اجتماعی، اقتصادی و فرهنگی تشخیص داده می‌شود. ما مدل پیشنهادی را **LSTM_WSD** و **CNN_WSD** می‌نامیم. در این مقاله از مجموعه داده فارسی توبیتر برای ارزیابی و مقایسه روش پیشنهادی با سایر روش‌های یادگیری ماشین و یادگیری عمیق از جمله **DNN**, **CNN**, **LSTM** استفاده شده، پیاده سازی این روش با نرم افزار پایتون انجام شده است. میزان دقیقت روش پیشنهادی برای **CNN-WSD** و **LSTM-WSD** به ترتیب **94.3** و **95.8** درصد است.

واژگان کلیدی: اعتقادکاوی، پردازش زبان طبیعی(**NLP**)، یادگیری عمیق، متن کاوی

درباره موجودیت‌هایی همچون محصولات، سرویس‌ها، سازمانها، افراد، رخدادها و موضوعات خاص میپردازد(**Liu, 2012**)

۱. مقدمه

تحلیل احساسات که همچنین نظرکاوی نامیده می‌شود، بخشی از مطالعات است که به تحلیل عقاید، احساسات و نگرش‌های مردم

نویسنده مسئول: امیر مسعود بیدگلی (DrBidgoli@gmail.com)
am_bidgoli@iau-tnb.ac.ir

پاسخ دهد و جایگزینی مناسب برای روش‌های سنتی باشد، یادگیری عمیق تاکنون از خود عملکرد بسیاری خوبی در بسیاری از شاخه‌های پردازش زبان طبیعی، خصوصاً تحلیل احساسات نشان داده است. مهمترین مزیت این روش، بینیازی از استخراج دستی ویژگی‌ها است که به جای تخصص در حوزه زبان‌شناسی بر دسترسی به حجم بالای داده‌ها تکیه دارد.

برای مقابله با این مشکلات، در این مقاله از روش جدید یادگیری عمیق مبتنی بر شدت احساس کلمات بر اساس دیدگاه کاربران، به تحلیل احساسات و اعتقادکاوی نظرات پرداخته شده است. در این پژوهش روش پیشنهادی برای اعتقادکاوی نظرات فارسی کاربران در شبکه اجتماعی توییتر اهداف زیر را دنبال می‌کند:

- در پیش پردازش کلمات اضافی با توجه به لیست حذف می‌شود و داده‌ها به عدد و بصورت برداری تبدیل می‌شوند.
- در روش پیشنهادی بدلیل استفاده از روش یادگیری عمیق(CNN ، LSTM) با تفکیک شدت احساس بر روی کلمه بر اساس دیدگاه کاربران در دقت رده بندی و تحلیل احساسات پیشرفت خوبی بدست آمده است.
- در روش پیشنهادی یک روش جدید با یادگیری عمیق با تفکیک و تحلیل احساسات در متون فارسی ارایه شده که متون در قسمت رمزنگاری به عدد تبدیل می‌شود تا متون به بردار تبدیل شود، این روش باعث افزایش دقت در اعتقادکاوی شود.
- ابتدا کلمات برگرفته از بدن اصلی اسناد آموزشی با روش اسکیپ گرام^۱ مشخص می‌شود و با مقایسه کلمات با واژگان، شدت احساسات آن مشخص می‌شود و در دسته‌های مثبت و منفی در بازه ۰+۲ و ۰-۲ مشخص می‌شود.
- تحلیل احساسات کاربران بر اساس شدت احساس کلمات می‌تواند دید دقیق و صحیح‌تری نسبت به نظرات کاربران در زمینه‌های مختلف را برای تصمیم‌گیری به ما بدهد.

در سالهای اخیر، محققین مطالعات متعددی در زمینه تحلیل احساسات با یادگیری عمیق برای زبان انگلیسی ارائه داده‌اند اما در زمینه اعتقادکاوی و تحلیل دیدگاه‌های کاربران تحقیقات زیادی انجام نشده است. همچنین تحلیل احساسات در متون فارسی نیز پیشرفت چشمگیری نداشته است. به همین دلیل در این کار به اعتقادکاوی با تحلیل شدت احساس کلمات بر اساس دیدگاه کاربران پرداخته ایم. در این کار جدیدترین مدل‌های یادگیری عمیق، مانند شبکه‌های عصبی عمیق (DNN)، شبکه‌های عصبی مکرر (RNN) و شبکه‌های عصبی کانولوشن (CNN) و مدل‌های یادگیری ماشین و روش پیشنهادی جدید CNN_WSD، LSTM_WSD بررسی و ارزیابی شده است.

در فعالیت‌هایی که تاکنون بر روی متون فارسی انجام شده اغلب به طبقه بندی متون با توجه به زمینه و حوزه مورد مطالعه پرداخته شده است، در زمینه اعتقادکاوی و تحلیل احساسات بر روی نظرات و متون فارسی پیشرفت چشمگیری انجام نشده، در فعالیت‌هایی که تاکنون انجام شده اغلب بدون در نظر گرفتن معنا، شدت حساسیت کلمات و دیدگاه کاربران و کلمات اضافی فقط نظرات را در دو گروه مثبت و منفی طبقه بندی می‌کنند. وقتی در تحلیل احساسات کاربران نظرات در گروه‌های مثبت و منفی طبقه‌بندی می‌شود، اهمیت و ضرورت این موضوع احساس می‌شود که شدت احساسات نیز مورد ارزیابی قرار گیرد، در این مقاله با استفاده از روش پیشنهادی اعتقادکاوی با یادگیری عمیق، ابتدا نظرات کاربران در دو قطب مثبت و منفی دسته بندی شده و برای هر قطب شدت احساسات بین بازه ۰-۲ و ۰+۲ نسبت داده شده است، سپس دیدگاه کاربران از نظر سیاسی، اجتماعی، اقتصادی و فرهنگی تعیین می‌شود، اعتقادکاوی با تعیین شدت احساسات بر اساس دیدگاه کاربران باعث می‌شود که سازمان‌ها، شرکت‌ها و محققین به راحتی نظرات کاربران را در زمینه‌های مختلف تحلیل کنند و تصمیم‌گیری مناسب و تعیین اهداف را انجام دهند.

بیشتر پژوهش‌های انجام شده در حوزه پردازش اطلاعات منتهی و تحلیل احساسات، بر روی داده کاوی و طبقه بندی اطلاعات، مانند تحلیل نظرات در دو قطب مثبت یا منفی تمرکز دارند. این در حالی است که در فرایند تصمیم‌گیری توسط مدیران سازمان‌ها و شرکت‌ها نیاز به اطلاع دقیق از دیدگاه و احساس کاربران می‌باشد، به عنوان مثال اگر درصد نظرات کاربران در دو قطب مثبت و منفی برابر باشد نمی‌توان تصمیم‌گیری انجام داد، اما در اعتقاد کاوی تعیین می‌کند که نیمی از کاربران با یک دیدگاه تعیین شده نظر مثبت و نیمی از آنها با دیدگاه دیگر نظر منفی دارند و یا حتی کاربرانی که از یک دیدگاه مشترک نظر داده اند چند درصد از آنها دیدگاه مثبت یا منفی دارند.

در اعتقادکاوی با تحلیل احساسات کاربران بر اساس شدت احساسات کلمات، زمینه‌ها و دیدگاه کاربران در دسته‌های سیاسی، اجتماعی، اقتصادی و فرهنگی مشخص می‌شود و نظرات کاربران را بر اساس دیدگاه آنها در دسته‌های مثبت و منفی بین بازه ۰-۲ و ۰+۲ تحلیل می‌کند.

در اعتقادکاوی و تحلیل احساسات بر اساس نظرات کاربران با یادگیری عمیق چالش‌ها و مشکلاتی مانند هزینه بالای آموزش بر اساس زمان یا حافظه استفاده شده، عدم وجود واژگان غنی و کامل، ابعاد بالای فضای ویژگی و ابهام در تشخیص مثبت یا منفی برخی از جملات وجود دارد. از سوی دیگر، علم یادگیری عمیق توانسته با پیشرفت خود به بسیاری از مسائل حوزه پردازش زبان طبیعی

^۱ Skip-gram

یادگیری عمیق شامل شبکه عصبی عمیق(DNN)، شبکه عصبی حلقوی(CNN)، شبکه عصبی مکرر(RNN) و است(کش دانگ و همکاران، ۲۰۲۰).

شبکه عصبی عمیق: یک شبکه عصبی با بیش از دو لایه است که برخی از آن‌ها لایه‌های پنهان هستند. شبکه‌های عصبی عمیق از مدل سازی ریاضی پیچیده برای پردازش داده‌ها به روش‌های مختلف استفاده می‌کنند.

شبکه عصبی حلقوی: یک نوع خاص از شبکه عصبی رو به جلو است که در اصل در مناطقی مانند بینایی ماشین، سیستم‌های توصیه کننده و پردازش زبان طبیعی به کار می‌رود. این یک معماری شبکه عصبی عمیق است، که به طور معمول از لایه‌های محکم و جمع با مخزن تشکیل شده است تا ورودی‌های یک لایه طبقه‌بندی کاملاً متصل را فراهم کند.

حافظه کوتاه مدت (LSTM): یک نوع خاص از شبکه عصبی مکرر(RNN) است که قادر به استفاده از حافظه طولانی به عنوان ورودی توابع فعال سازی در لایه پنهان است. سایر روش‌های یادگیری عمیق در (علی کرمی و همکاران، ۲۰۲۳) بیان شده است.

3. کارهای گذشته

در اوایل دهه ۱۹۶۰ مردم شروع به مطالعه طبقه‌بندی متن کردند. در آن زمان قوانین طبقه‌بندی با توجه به پدیده‌ها و قوانین زبان نوشته می‌شد. تا دهه ۱۹۹۰، مردم شروع به مطالعه تکنولوژی طبقه‌بندی خودکار مبتنی بر کامپیوتر کردند. در این روشها ابتدا به پیش برچسب‌گذاری داده‌ها، یادگیری قوانین و سپس به طبقه‌بندی و آموزش نمونه‌های جدید از دسته‌های ناشناخته به طور خودکار پرداخته شد. نتایج نشان می‌دهد که در زمینه حجم داده‌های بزرگ، دقت طبقه‌بندی آن بسیار بهتر از تعریف قوانین است. بنابراین تحقیقات کنونی بر طبقه‌بندی خودکار متون با الگوریتم-

های هوش مصنوعی مرکز است(یاو و همکاران^۱، ۲۰۱۱). طبقه‌بندی متون یکی از وظایف اصلی یادگیری ماشین است. هدف آن طراحی الگوریتم‌های مناسب برای استخراج ویژگی‌ها و طبقه‌بندی متون به صورت خودکار است. در گذشته، اساساً از طبقه‌بندی کلمات کلیدی و طبقه‌بندی سنتز معنایی با شبکه عصبی استفاده می‌شد.

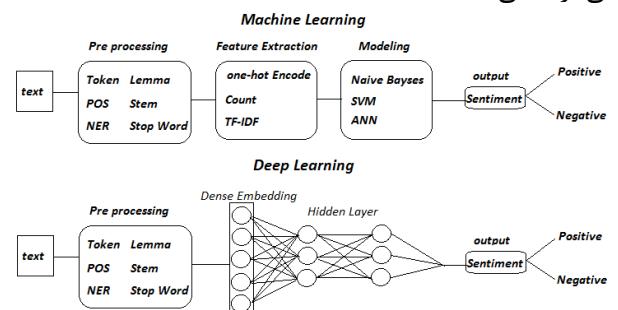
محققان در طول سال‌های ۲۰۰۰-۲۰۱۵ به ارزیابی و مقایسه روش‌های تجزیه و تحلیل احساسات و متن کاوی پرداخته اند(پیراری و همکاران، ۲۰۱۷). در زمینه تحلیل‌های احساسی مانند استخراج احساسات، نظر کاوی، استخراج نظرات و اعتقادکاوی،

تا مشکلات مختلف در رابطه با تجزیه و تحلیل احساسات را حل کند. در روش پیشنهادی برای اعتقادکاوی و رده‌بندی نظرات از یادگیری عمیق با تفکیک شدت احساسات کلمات بر روی مجموعه داده‌های فارسی استفاده شده، این روش سبب استخراج ویژگی‌های مناسب و افزایش دقت و تشخیص شدت احساسات در بازه +۲ و -۲ می‌شود، بنابراین روش پیشنهادی برای بهبود تضمیم‌گیری و نظرکاوی در متون فارسی اهمیت بالایی دارد.

در این مقاله در بخش اول مقدمه‌ای در زمینه اعتقادکاوی و رده‌بندی متون فارسی، در بخش دوم ادبیات تحقیق و پیش زمینه ای در مورد روش‌های یادگیری عمیق، در بخش سوم به کارهای گذشته در زمینه اعتقادکاوی و تحلیل احساسات پرداخته شده، در بخش چهارم پیش پردازش متون فارسی و اعتقادکاوی نظرات با روش پیشنهادی LSTM_WSD و CNN_WSD ارایه شده، در بخش پنجم پردازش داده‌ها، در بخش ششم نتایج و آزمایشات روش پیشنهادی و مقایسه با سایر روش‌ها و سپس به نتیجه گیری پرداخته شده است.

2. ادبیات تحقیق

در روش پیشنهادی اعتقادکاوی مبتنی بر الگوریتم یادگیری عمیق می‌باشد، قبل از بررسی و تحلیل مدل بهینه شبکه عصبی عمیق در روش پیشنهادی مقدماتی از یادگیری عمیق بیان می‌شود. یادگیری عمیق یک رویکرد چند لایه را با لایه‌های پنهان شبکه عصبی تطبیق می‌دهد. در روش‌های یادگیری سنتی ماشین، ویژگی‌ها به صورت دستی یا با استفاده از روش‌های انتخاب ویژگی مشخص و استخراج می‌شوند. اما در مدل‌های یادگیری عمیق، ویژگی‌ها به طور خودکار استخراج می‌شوند و به دقت و عملکرد بهتری دست می‌یابند. شکل ۱ اختلاف‌های طبقه‌بندی و تحلیل احساسات بین دو رویکرد یادگیری ماشین و یادگیری عمیق در نشان می‌دهد. شبکه‌های عصبی مصنوعی و یادگیری عمیق در حال حاضر بهترین راه حل‌ها را برای بسیاری از مشکلات در زمینه‌های اعتقادکاوی، تحلیل احساسات، تشخیص گفتار و پردازش زبان طبیعی ارائه می‌دهند.



شکل ۱: تفاوت بین دو رویکرد تحلیل احساسات با روش‌های یادگیری ماشین (بالا) و یادگیری عمیق (پایین).

¹ Yao, Q.Z.; Song, Z.L.; Peng, C.

(شمس و همکاران، ۲۰۱۲)، پژوهش دیگری نیز تحت عنوان ایجاد یک سیستم نظرکاوی با استفاده از الگوریتم‌های با ناظر انجام گرفته است. در گام نخست آن، یک لغتنامه احساس برای زبان فارسی به کمک شبکه واژگانی فارسی موجود، فارس نت، گسترش داده شده است. این پژوهش با استفاده از سه الگوریتم یادگیری ماشین، شامل: ماشین بردار پشتیبانی، بیز ساده و رگرسیون منطقی به ارزیابی روش پیشنهادی خود پرداخته است (صیری و همکاران، ۲۰۱۴).

یکی از روش‌های اعتقادکاوی و تحلیل احساسات بر روی متون فارسی، تحلیل احساسات کاربران بر اساس دیدگاه آنها است که با روش‌های یادگیری عمیق CNN، LSTM و DNN و تکنیک تعبیه کلمات^۳ و TF-IDF به آن پرداخته شده بر اساس نتایج این مقاله روش تعبیه کلمات^۴ با LSTM برای تحلیل احساسات مبتنی بر دیدگاه کاربران نتایج بهتری را داشته است (علی کرمی و همکاران، ۲۰۲۲).

دو و هانگ^۵ مقاله‌ای تحت عنوان تحقیقات طبقه‌بندی متن با شبکه‌های عصبی مکرر مبتنی بر توجه را ارایه دادند که روش پیشنهاد شده در این مقاله مزایای هر دو روش را در نظر می‌گیرد. با استفاده از یک مکانیزم توجه بر روی یادگیری وزن برای هر کلمه استفاده می‌شود. در این روش، کلمات کلیدی وزن بیشتری خواهند داشت و کلمات رایج وزن کمتری خواهند داشت. بنابراین، در نظرکاوی متون و اعتقادیابی نه تنها همه کلمات را در نظر می‌گیرد بلکه توجه بیشتری به کلمات کلیدی نیز می‌کند (دو و هانگ، ۲۰۱۸).

یکی دیگر از پژوهش‌های صورت گرفته در زبان فارسی تحت عنوان بهره‌برداری از یادگیری عمیق در تحلیل احساسات است. در این پژوهش از مدل یادگیری عمیق شامل شبکه عصبی کانولوشن استفاده شده است. و در نهایت مدل یادگیری عمیق معرفی شده خود را با روش‌های کم عمق یادگیری ماشین همچون پرسپترون چندلایه مقایسه نموده اند (دشتی پور و همکاران، ۲۰۱۸).

صیری و کبیری مقاله‌ای تحت عنوان بهبود تجزیه و تحلیل احساسات و اعتقادیابی در زبان فارسی با استفاده از اصلاح واژگان را ارایه دادند، که هدف از تجزیه و تحلیل احساسات^۶ مبتنی بر اصلاح واژگان این است که مشکل استخراج افکار مردم از نظرات آنها در وب را با استفاده از واژگان کلمات از پیش تعریف شده رفع کنند. با این حال، اعتقادکاوی و نظرکاوی برای زبان فارسی در مقایسه با

روش‌هایی برای تجزیه و تحلیل احساسات و اندیشه کاوی در کلمه، جمله و سطح سند، برای نظرات مصرف کنندگان در عبارات بیان شده است. با توجه به فازی بودن شخصیت، تکنیک‌های یادگیری ماشین سنتی نمی‌توانند نظرات را به خوبی نشان دهند. برای رفع این مشکل روش تحلیل احساسات با فاز معنایی برای حل مسئله پیشنهاد شده است (فانگ و همکاران، ۲۰۱۸).

مطالعه افکار عمومی می‌تواند اطلاعات ارزشمندی را در اختیار ما قرار دهد. تجزیه و تحلیل احساسات در شبکه‌های اجتماعی، مانند توییتر یا فیس بوک، به ابزاری قدرتمند برای تحلیل نظرات کاربران تبدیل شده و کاربردهای گسترده‌ای دارد. با این حال، چالش‌هایی در صحت تحلیل احساسات در پردازش زبان طبیعی (NLP) پیش آمده. در سال‌های اخیر نشان داده شده است که مدل‌های یادگیری عمیق یک راه حل امیدوار کننده برای چالش‌های تحلیل احساسات و اعتقادکاوی است. در مطالعاتی مانند قطبیت احساسات که از یادگیری عمیق برای حل مشکلات تحلیل احساسات استفاده شده است، مدل‌هایی با استفاده از فرکانس سند، فرکانس معکوس (TF-IDF) و تعبیه کلمه بر روی یک سری مجموعه داده‌ها اعمال شده اند (کچ دانگ و همکاران، ۱۰۲۰).

با توجه به ویژگی‌های مورد استفاده برای بهره‌برداری از نظرات مصرف کننده، مدل کیف واژه‌ها بیانگر سند سنتی است که در آن فرکانس‌های کلمه برای هر کلمه (عبارت) در واژگان محاسبه می‌شود (جانسون و همکاران، ۲۰۱۵). با این حال، این رویکرد منجر به بازنمایی استناد پراکنده در ابعاد بالا می‌شود، علاوه بر این، این روش معنی کلمه را نادیده می‌گیرد. برای غلبه بر این مشکلات، روش تعبیه کلمات به جای تک کلمات معرفی شده اند، که یک زمینه کوتاه در نظر گرفته شده است (فانگ و همکاران، ۲۰۱۵). در مقایسه روش تعبیه کلمات با مدل کیف واژه^۷، روش تعبیه کلمات در مدل سازی متن کلمه و معنی کلمه نیز مؤثر است. بعد از تولید اسناد مناسب، می‌توان از مدل‌های مختلف شبکه عصبی و سایر روش‌های یادگیری ماشین، مانند ماشین‌های بردار پشتیبان، برای برای تولید کلمات تعبیه شده و طبقه‌بندی عقاید استفاده کرد (دو و همکاران، ۲۰۱۹).

یکی از اولین پژوهش‌های صورت گرفته در زمینه نظرکاوی برای زبان فارسی مربوط به گردآوری مجموعه داده‌ای با نام PersianClues است. این پژوهش با استفاده از یک روش ابتکاری بدون ناظر به تحلیل احساسات می‌پردازد. در واقع تغییری که در این روش صورت گرفته اضافه کردن مجموعه کلمات حاوی بار معنایی به عنوان بردار ویژگی‌ها در مرحله یادگیری است

³ Word Embedding

⁴ Word Embedding

⁵ C. Du, L. Huang

⁶ Sentiiment Analysis

¹ N. cach dang et al

² bag-of-words

یک معماری شبکه عصبی کانولوشن دو طرفه توسط وانگ پیشنهاد شد که از دو لایه دو طرفه LSTM و GRU استفاده می‌کند تا با اتصال دو لایه پنهان از جهت‌های مخالف به یک زمینه، هم زمینه‌های گذشته و هم آینده را استخراج کند (وانگ و همکاران، ۲۰۱۹).

وانگ و همکاران یک روش افزایش بازنمایی خلاف واقع (CRA) را برای آموزش و طبقه‌بندی احساسات در اعتقادیابی نظرات کاربران ارائه کردند تا نتیجه عملکرد تعمیم دامنه هدف را بهبود بخشدند(وانگ و وان، ۲۰۲۲^۴).

سیجی مای و همکاران یک چارچوب جدید با نام HyCon برای یادگیری متصاد ترکیبی نمایش سه وجهی برای احساسات چندوجهی ارائه کردند (مای و همکاران، ۲۰۲۲^۵). ترکی و روی یک روش تشخیص سخنان منفی را با استفاده از تجسم ابری کلمه و یادگیری گروهی با بردار شمارنده را ارائه کردند، آنها از یک چارچوب محاسباتی استفاده کردند که تکنیک‌های تقویت داده‌ها را برای بازنمایی و عملکرد بهتر استفاده کردند (ترکی و روی، ۲۰۲۲^۶).

۴. روش پیشنهادی یادگیری عمیق با تفکیک شدت احساس کلمات

در روش پیشنهادی مجموعه داده توییتر فارسی برای تحلیل احساسات و اعتقادکاوی نظرات کاربران استفاده شده است. تحلیل احساسات براساس قطبیت انجام شده است، قطبیت جملات در این پیکره به صورت عددی بین +۲ و -۲. نمایش داده شده اند که عدد

کوچکتر نشانگر قطبیت کمتر (بار منفی بیشتر) است.

هدف اصلی در متن‌کاوی، تحلیل احساسات کاربران بر اساس قطبیت، تشخیص شدت احساسات با تفکیک احساس-کلمه است.

در این مقاله تحلیل احساسات با روش پیشنهادی یادگیری عمیق مبتنی بر احساس-کلمه انجام می‌شود، که برای آنالیز دقیق و

صحیح تر نظرات در دو مرحله زیر انجام می‌شود:

در مرحله اول احساسات کاربران در دسته‌های مثبت و منفی در باز +۲ و -۲ با در نظر گرفتن کلمه- احساس مشخص می‌شود. به صورتی که کلمات با استفاده از مدل اسکیپ گرام آموزش داده می‌شود.

در مرحله دوم واژگان بدست آمده از بدنه اصلی استناد با چند واژگان مقایسه می‌شود تا قطبیت و شدت احساسات مبتنی بر واژگان را اضافه کند.

انگلیسی متفاوت است. استفاده از روش مبتنی بر واژگان در فارسی، یک رشته جدید است. منابع محدودی برای تحلیل احساسات و نظرکاوی در زبان فارسی وجود دارد که دقیق روش‌های موجود مبتنی بر واژگان پایین تر از زبان‌های دیگر است(بصیری و بکیری، ۲۰۱۸).

اورولاگین^۱ مقاله‌ای تحت عنوان یک رویکرد جدید برای تجزیه و تحلیل احساسات و تجسم فکری و طبقه‌بندی خلاصه اخبار ارایه داد که در این کار روش‌های موثر برای استخراج داده‌ها را پیشنهاد می‌کند. در این روش بصورت یک مرور کلی و خلاصه‌ای از متن و تحلیل احساسات می‌تواند احساسات بیان شده در متن را به صورت محاسبات به دست آورد. خلاصه سازی متن و تحلیل احساسات بر روی اخبار بی‌سی انجام شده است. روش خلاصه سازی با متن جایگزینی برای تجزیه و تحلیل احساسات مورد استفاده قرار می‌گیرد و طرح‌های تجسم سه بعدی برای نشان دادن اطلاعات احساسات ارائه شده است(اورولاگین، ۲۰۱۸).

کیویو و لی^۲ مقاله‌ای تحت عنوان تجزیه و تحلیل احساسات متن کوتاه در میکروبلاگ براساس تجزیه و استنگی را ارایه دادند، این روش برای حل مشکلات ارتباط بین کلمات عاطفی و اصلاح کننده و احساسات متن کوتاه از طریق ساختار احساسات و قوانین محاسبه احساسات پیشنهاد شده، که به تحلیل احساسات متن کوتاه کمک می‌کند. احساس متن کوتاه با توجه به تأثیرات مختلف روابط میان جملات و سهم هر جمله به محاسبه اندیشه متن کوتاه پرداخته می‌شود(کیویو و لی، ۲۰۱۸). همچنین با در نظر گرفتن معنای کلمات در نظرکاوی، با توجه به اینکه برخی از ویژگی‌های انتخابی مناسب نیستند و منجر به افزایش خطاهای در طبقه‌بندی می‌شوند، ویژگی‌های بهینه انتخاب می‌شوند و سپس این ویژگی‌ها به ماشین یادگیری داده می‌شود(علی کرمی و همکاران، ۲۰۱۹).

در زمینه تحلیل احساسات، عنان روشی را برای اعتقادیابی و تفکر کاوی در سطح کلمه، جمله و سند برای نظرات مصرف کنندگان به زبان چینی ارائه کرد. (عنان^۳، ۲۰۲۰)، او یک رویکرد مجموعه ای برای انتخاب ویژگی ارائه کرد، که چندین لیست ویژگی‌های فردی را که با روش‌های مختلف انتخاب ویژگی به دست آمده اند جمع می‌کند تا زیر مجموعه ویژگی‌های قوی تر و کارآمدتری به دست آید. تا تجزیه و تحلیل احساسات در مورد بررسی محصول بر اساس جاسازی کلمات وزن دار و شبکه‌های عصبی عمیق انجام دهد (عنان، ۲۰۲۲).

⁴ K. Wang and X. Wan

⁵ S. Mai, Y. Zeng, S. Zheng and H. Hu

⁶ T. Turki and S.S. Roy

¹ Siddhaling Urologin

² Lirong Qiu, Jie Li

³ Onan

برای به دست آوردن بازنمایی سند برای لایه بعدی در معماری CNN_WSD، LSTM_WSD میانگین مقادیر بردارها از ماتریس وزن تعییه شده محاسبه شد.

برای تکمیل بازنمایی احساس-کلمه با قطبیت و شدت احساسات، از چندین واژگان احساساتی از پیش تعریف شده استفاده کردیم. برای به دست آوردن یک ارزیابی احساساتی معتبر، پیشنهاد می شود به یک واژگان واحد اعتماد نکنید. علاوه بر این، ترکیبی از شخص های احساسات مبتنی بر واژگان، مشکل حساسیت به عقاید غیرمستقیم را که معمولاً در مدل های یادگیری ماشین وجود دارد، غلبه می کند. برای محاسبه قطبیت احساسات، از دو واژگان دست ساز کلمات مثبت و منفی استفاده کردیم(بصیری و همکاران، ۲۰۱۸).

یکی از کمبودهای این واژگان این است که وزن مساوی بدون توجه به شدت احساس آنها به همه کلمات اختصاص می یابد. برای پرداختن به این مسئله، ما شخص های شدت احساسات به دست آمده از واژگان زیر را با نقاط قوت احساساتی از پیش آموزش دیده درج کردیم: بنابراین ، نمرات کلی مثبت و منفی را می توان برای هر واژگان محاسبه کرد. علاوه بر این، ترکیب چندین واژگان، پوشش واژگان بالاتری را تضمین می کند(هاجک و همکاران، ۲۰۲۰).

برای به دست آوردن نمایندگی n-gram ، وزن هر n-gram به شرح زیر محاسبه می شود:

$$w_{ij} = (1 + \log(tf_{ij})) \times \log(N/d_{fi}) \quad (3)$$

جایی که ω وزن نام n-gram را در سند ω (بررسی) بیان می کند، N ; d_{fi} و tf_{ij} به ترتیب بیانگر فرکانس اصطلاحات و اسناد^۴ هستند. بنابراین، طول بررسی در نظر گرفته می شود ، و وزن نسبتاً بالاتری به n-gram نادر اختصاص می یابد. برای پردازش بیشتر، n-gram ها با توجه به وزن آنها رتبه بندی می شوند، و n-gram های برتر برای ورود به لایه بازنویسی اسناد در معماری CNN_WSD، LSTM_WSD انتخاب می شوند.

⁴ term and document frequency

برای آنالیز دادها پیش پردازش بر روی اسناد آموزشی انجام شده و داده های گسیخته^۱ حذف شده، و بردارهای مبتنی بر^۲ از tf-idf از متن ورودی به دست آمده و بردارهای حاصله، نرمال سازی می شوند. در مرحله پیش پردازش کاهش ابعاد بروی متون انجام می گردد(هاجک و همکاران، ^۳ ۲۰۲۰). در نهایت بعد از پیش پردازش که در زیر جزئیات آن شرح داده شده، داده های پیش پردازش شده به عنوان داده های آموزشی برای اعتقاد کاوی و

رد هدیندی نظرات روش پیشنهادی اعمال می گردد.

در تحلیل احساسات و دسته بندی خودکار نظرات از یادگیری CNN_WSD، LSTM_WSD عمیق مبتنی بر احساس-کلمه CNN(Convolutional Neural Networks)، LSTM(Long-Short-Term Memory) با دو لایه پنهان متراکم برای پردازش در ویژگی های ورودی استفاده می شود. این دو نمایندگی شامل احساس-کلمه و n-gram است.

بازنمایی کلمه- احساس در دو مرحله تولید می شود: در مرحله اول، تعییه کلمات با استفاده از مدل اسکیپ گرام آموزش داده می شود. مرحله دوم ، واژگان به دست آمده از بدنه اصلی اسناد ورودی با چند واژگان مقایسه شده است تا قطبیت و شدت احساسات مبتنی بر واژگان را اضافه کند(علی کرمی و همکاران، ۲۰۲۳).

برای محاسبه ماتریس وزن تعییه شده، عملکرد تعییه شده برای هر کلمه w_t در واژگان اعمال می شود.تابع تعییه برای دنباله کلمات $W = \{w_1, w_2, \dots, w_t, \dots, w_T\}$ کلمات آموزش داده شده

تا عملکرد تابع هدف زیر به حداکثر برسد:

$$E = \frac{1}{T} \sum_{t=1}^T \sum_{c \leq j \leq c} \text{Logp}(W_t + j | W_t) \quad (1)$$

C نمایانگر شاع پنجره متن است (چند کلمه اطراف را در نظر می گیریم و $p(W_t + 1 | W_t)$ احتمال کلمه خروجی با توجه به کلمات ورودی محاسبه شده با استفاده از الگوریتم سلسه مرتبی(softmax است.

$$\rho(\omega_0 | \omega_I) = \prod_{j=1}^{L(\omega)-1} \sigma(\|n(\omega, j+1) = ch(n(\omega, j))\| v'_{n(\omega_0, j)} v_{\omega I}) \quad (2)$$

جایی که w_I و w_O به ترتیب کلمات ورودی و خروجی هستند. v'_{wI} و v'_{wO} به ترتیب نشانگرهای بردار کلمات ورودی و خروجی را نشان می دهد. $(ch(n(\omega, j))$ گره j ام در درخت باینری است. $L(w)$ طول مسیر در درخت است. $(ch(n(\omega, j))$ یک گره فرزند را نشان می دهد. σ یک تابع عملکرد سیگموئیدی را مشخص می کند، در صورتی که اگر x صحیح باشد، $1 = [[x]]$ ؛ در غیر این صورت $[[x]] = -1$.

¹Outlier

²term frequency-inverse document frequency

³Hajek P., Barushka A., Munk M.

```

while i < n do
if P(Wo|Wi)
vw is the vector marker of the input words and v'w
represent
the vector marker of the output words.
x= Softmax(Wt + j) // Equation (2)
If x is integer, [[x]] = 1; Otherwise [[x]] = -1.
If x is correct, [[x]] = 1; Otherwise [[x]] = -1.
end if where (Wij weight of each n-gram in the document)
// Equation(3)
Repeating number or using the frequency product of each
word
tf_idf // Equation (4)
i= i + 1
Obtain well-trained sentiment- word embeddings(WSD):
using
synoumym Word and the words of the context around it.
end while
return.

```

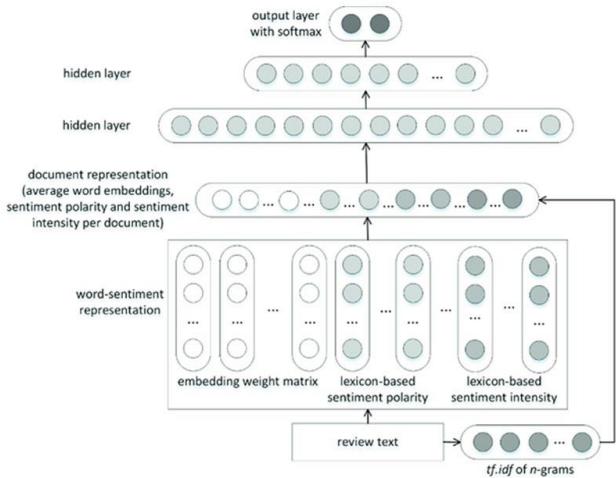
مراحل طراحی روش پیشنهادی در زیر بیان شده:

1.4 پیشپردازش و خلاصه سازی اولیه

در حقیقت، پیشپردازش وظیفه نگاشت متن داده شده به یک نمای منطقی را بر عهده دارد. به عبارت دیگر استخراج ویژگی و وزنده‌ی و کاهش ابعاد در این قسمت انجام می‌گیرد. بسته به کاربرد استخراج ویژگی می‌تواند بسیار ساده و یا بسیار مفصل باشد. تحلیل واژگانی شامل عملیات مربوط به یکسان سازی متن، قواعد مربوط به نشانه‌گذاری‌ها و مرزبندی بین کلمات می‌باشد. بعد از این مرحله عموماً دسته‌ای از کلمات بی ارزش که متنابعاً تکرار می‌شوند و بار معنایی خاصی ندارند: مانند حرف ربط ("و"، "که"، "تا"، "وقتیکه"، "اگر"، "اما"، "اینکه")، حرف اضافه ("به"، "با"، "از"، "در")، فعل ربطی ("است"، "بود"، "شد") و حرف تعریف ("یک" در "یک دانشجوی نمونه کسی است که ...") از متن داده شده حذف می‌شوند. سپس با استفاده از الگوریتم‌های ریشه‌یابی، به منظور بهینه‌سازی ویژگی‌های استخراج شده، کلمات ریشه‌یابی می‌شوند. در نهایت با استفاده از گروه‌های اسمی کلمات دسته‌بندی می‌گردد.

الگوریتم ۲. نحوه تخصیص شدت احساس کلمات

- 1: A set of words in Vocabulary = (W1,W2,W3,...,WV)
- 2: A dictionary of input words and their corresponding sentiment polarity
- 3: // Get sentiment polarity of words based on SentiWordNet and Sentipers lexicons
- 4: Sentiment_class = {} // Dictionary of words and their corresponding polarity class
- 5: for each W in Vocabulary:



شکل ۲- معماری پیشنهادی برای استخراج نظرات و اعتقادکاوی

دو لایه پنهان بعدی برای پردازش رابطه پیچیده بین نمایش اسناد و کلاسهای مثبت / منفی از خروجی استفاده می‌شود. برای جلوگیری از اضافه کردن اتصالات و اثربخشی آموزش، به ترتیب از یکپارچه سازی ترک خورده‌ی 0.2 و 0.5 برای ورودی و دو لایه پنهان استفاده کردیم. الگوریتم نزول شبیه مینی دسته ای با $b = nh_2$ در دو لایه پنهان = {24 و 25، 26} برای بهترین نتایج برای $nh_1 = 24$ و $nh_1 = 25$ در زیر ارائه می‌شود، بهترین نتایج برای $nh_2 = 24$ و $nh_2 = 25$ در نورون بدست آمد. توجه داشته باشید که ما همچنین با یک لایه پنهان آزمایش کرده ایم اما بدون پیشرفت. عملکرد هدف با از دست دادن آنتروپی متقاطع نشان داده شد. پیچیدگی کلی مدل ارائه شده می‌تواند به صورت:

$O(b \times I \times (m \times nh_1 + nh_1 \times nh_2 + nh_2 \times nO))$ بیان شود، که I تعداد تکرارها را نشان می‌دهد. m تعداد ویژگی‌های موجود در لایه ارائه اسناد را نشان می‌دهد. nO و nh_2, nh_1 به ترتیب تعداد نورون‌ها در لایه‌های پنهان اول و دوم و لایه خروجی را نشان می‌دهند.

الگوریتم ۱. الگوریتم روش پیشنهادی تحلیل احساسات

Parameters: $n(w, j)$ is the j th node in the binary tree. $L(w)$ is the path length in the tree. $ch(n)$ is a child node. $\sigma(x)$ specifies a sigmoid function.

Input: Set of words in a sentiment lexicon $w = \{w_1, w_2, \dots, w_n\}$

Output: Well-trained sentiment- word embeddings Et
Initialization

$w \text{ embed}(w) // \text{Equation (1)}$

$i = 0, n = \text{total number of documents}$

1 mini-batches

کلاس‌های کمتر و تعداد رخداد بیشتر آن در یک کلاس، کلماتی را به عنوان ویژگی نهایی انتخاب کنند که هر چه بیشتر نماینده یک کلاس خاص باشند.

2.1.4 بازنمایی متون با روش تعییه واژه‌های عصبی

برای وزن‌دهی به ویژگی‌ها می‌توان از رویکردهای متفاوتی بهره بردن. در ساده‌ترین حالت این وزن‌دهی می‌تواند به صورت بایبری انجام شود. انتخاب دیگر وزن‌دهی به هر کلمه با توجه به تعداد تکرار هر کلمه و یا استفاده از حاصلضرب فرکانس هر کلمه در معکوس فرکانس سند که معمولاً به صورت زیر تعریف می‌شود:

$$TF - IDF(ti, dj) = tf(ti, dj) \times \log(N/(N(ti))) \quad (5)$$

تعداد اسنادی از مجموعه $N(ti)$ و N نماینده تعداد کل اسناد می‌باشد.

در نظرکاری داده‌ها با یادگیری عمیق ابتدا داده‌های متنی باید با روش‌های رمزگاری به عدد تبدیل شود، زیرا هر مدل پایه ریاضی دارد. با وجود روش‌های برداری فوق که اغلب در الگوریتم‌های یادگیری ماشین سنتی استفاده می‌شود، ما از تعییه واژه‌های عصبی در مدل‌های یادگیری عمیق بهره مند می‌شویم که هر کلمه به یک بردار کم ابعاد به نام ویژگی کلمه تبدیل می‌شود (تورین و همکاران، 2010). تعریف کلمات در این نمایش باعث می‌شود که کلمات مشابه مستقیماً پیدا شوند. بنابراین می‌توانیم از این مزیت برای کاوش نظر نیز استفاده کنیم. به طور خلاصه، هر جمله رمزگذاری می‌شود، کلمات بعدی برداری می‌شوند. در نتیجه، هرچه بردارهای مشابه بیشتری در میان جملات قرار گیرند، شباهت بیشتری خواهند داشت. شایان ذکر است که تعییه کلمه عصبی نه تنها یک ریدیاب مترادف است بلکه یک روش برای یافتن کلمات از یک خانواده (به عنوان مثال گربه، سگ) است. این بردارها به دو صورت لایه جاسازی آنلاین و جاسازی کلمات از قبل آموزش داده شده انجام می‌شود، روش لایه جاسازی آنلاین به مجموعه داده موجود متنکی است و در فرایند یادگیری عصبی عملی خواهد شد. در حقیقت، بردارهای خروجی از ورودی با استفاده از هیچگونه عمل ریاضی محاسبه نمی‌شوند. بنابراین، هر کلمه در جملات همانطور که ظاهر می‌شود با یک عدد صحیح رمزگذاری می‌شود. در این حالت، VS تعداد کلمات مجموعه واژگان را نشان دهد و Ev بعد تعییه بردارها را نشان می‌دهد. سپس، پس از آموزش شبکه عصبی، انتظار داریم یک بردار تعییه شده در اندازه به شرح زیر باشد. در این میان، شکل ۳ نحوه آنلاین بودن را نشان می‌دهد.

```

6: Score = 0
7: Word = Lemmatization(W) // Lemmatize the word
8: Synsets = GetSynsets_SentiWordNet(Word) // Obtain the
   sysnets of a word from SentiWordNet
9: if length (Synsets) > 0 do // That means the word exists in
   SentiWordNet lexicon
10: Score = Average( Synsets.positive_scores) - Average(
   Synsets.negative_scores)
11: else
12: Score = getPolarity_SenticNet(Word)
13: if Not Score do // That means the word does not exist in the
   SenticNet lexicon
14: Score = getPolarity_VADER(Word)
15: end if
16: end if
17: // Assign sentiment class based on the score obtained before
18: append (W: "Strong Negative") to Sentiment_class ifScore <= -1
19: append (W: "Negative") to Sentiment_class if-1 < Score < 0
20: append (W: "Neutral") to Sentiment_class ifScore == 0
21: append (W: "Positive") to Sentiment_class if0 < Score < 1
22: append (W: "Strong Positive") to Sentiment_class ifScore >= 1
23: end for return Sentiment_class

```

همانطور که در الگوریتم ۲ خلاصه شده است، کلمه مورد نظر با ارزش امتیاز احساسات آن از مجموعه داده جایگزین شده است. از طرف دیگر، از آنجایی که کلمه ممکن است در قطبیت‌های مختلف در Sentpres و SentiWordNet ظاهر شود، از تفاوت میانگین امتیازات مثبت و منفی استفاده کردیم. این با فرمول زیر نشان داده می‌شود:

$$Score = \sum i = 1kSynsetp(i)k - \sum i = 1kSynsetn(i)k \quad (4)$$

در فرمول ۴ مقدار k به تعداد ظاهر کلمه اشاره دارد، $Synsetp$ نشان‌دهنده امتیاز مثبت و $Synsetn$ نشان‌دهنده امتیاز منفی است.

1.1.4 انتخاب ویژگی اولیه

انتخاب ویژگی، تکنیکی است که برای مواجهه با داده‌های با ابعاد بالا استفاده می‌شود. مسئله اصلی این است که داده‌هایی که دارای ابعاد بالا هستند زمان بیشتری را برای پردازش صرف می‌کنند. یکی از راه‌های کم کردن زمان محاسبات، انتخاب ویژگی‌هایی از فضای مسئله است که در تعیین جوابها موثر هستند و از باقی ویژگی‌ها صرف نظر می‌شود. بدین صورت داده‌هایی با ابعاد کمتر به وجود می‌آیند که بعد از انجام اعمالی نظیر رده‌بندی، جواب‌هایی مشابه داده‌های اولیه تولید می‌کنند، در روش پیشنهاد شده برای حل این مسئله از پارامترهای معکوس فرکانس مطابقت (ICF) استفاده می‌کند و مربوط به هر کلمه (uni) و یکنواختی (ICF) سپس کلمه‌ای را انتخاب می‌کند که حد آستانه کوچکتر از مشخص و بزرگتر از حد آستانه تعیین شده داشته باشد. در uni حقیقت این پارامترها سعی می‌کنند با امتیاز دادن به تکرار کلمه در

¹High dimensional

در این مقاله از مجموعه داده توییتر فارسی استفاده شده، نظرات فارسی در مجموعه داده شبکه اجتماعی توییتر شامل ۱۰۰۰۰۰ سند است، برای هر دسته نظر کاوی با مثبت و منفی بودن نظر کاربران نمایش داده می‌شود. مجموعه داده توییتر شامل فیلدهای زیر می‌باشد:

۵. نتایج و آزمایشات

در اعتقادیابی هر کلمه به عنوان یک ویژگی در داده‌های آموزشی برای ردهبندی در نظر گرفته می‌شود و کلمات در متون فارسی بر اساس نرخ تاثیر در نظر کاوی در ردهبندی اندازه‌گیری می‌شود و بر اساس میزان دقت Acc و زمان ردهبندی اندازه‌گیری می‌شود. این آزمایشات بر روی مجموعه داده توییت‌با ۱۰۰۰۰۰ سند انجام شده است. ما از مدل‌های یادگیری عمیق مبتنی بر شدت احساسات کلمات با TF-IDF و تعییه کلمات بر روی مجموعه داده‌های توییت استفاده کرده ایم. برای یادگیری تعییه کلمات (word embeddings)، از مدل Skip-Gram برای آموزش داده‌ها استفاده شده است.

1.5 مجموعه داده توپیتر

نظرات فارسی در مجموعه داده شبکه اجتماعی توییتر شامل ۱۰۰۰۰۰ سند است، برای هر دسته نظرکاوی با مثبت و منفی بودن نظر کاربران نمایش داده می‌شود. مجموعه داده توییتر شامل فیلدهای زیر می‌باشد:

- _ “target” is the polarity of the tweet;
 - _ “id” is the unique ID of each tweet;
 - _ “date” is the date of the tweet;
 - _ “query_string” indicates whether the tweet has been collected with any particular query keyword (for this column, 100% of the entries labeled are with the value “NO_QUERY”);
 - _ “user” is the Twitter handle name of the user who tweeted;
 - _ “text” is the verbatim text of the tweet.

id	text	user_id	name	username	created_at	mentions	hashtags	urls	replies	retweets	coordinates	lang
1000	4382 793	1000	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:15:25 2015
1001	4432 200	1001	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1002	4432 100	1002	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1003	3979 100	1003	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1004	3979 52	1004	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1005	3979 52	1005	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1006	3979 61	1006	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1007	3979 100	1007	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1008	3979 100	1008	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					11:16:02 2015
1009	11693 3046	1009	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					19:01:56 2015
1010	8844 2014	1010	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					19:34:45 2015
1011	8844 2014	1011	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					19:34:45 2015
1012	7209 1766	1012	[https://t.co/...]	[https://t.co/...]	2.29E+09 UTC		[https://t.co/...]					17:41:10 2015
1013	5915 1349	1013	[https://t.co/...]	[https://t.co/...]	2.29E+09 UTC		[https://t.co/...]					19:16:25 2015
1014	5915 1349	1014	[https://t.co/...]	[https://t.co/...]	2.29E+09 UTC		[https://t.co/...]					19:16:25 2015
1015	7375 1322	1015	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					20:20:20 2015
1016	7375 1322	1016	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					20:20:20 2015
1017	6853 2010	1017	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					14:55:44 2015
1018	7899 1790	1018	[https://t.co/...]	[https://t.co/...]	2.29E+09 UTC		[https://t.co/...]					15:13:16 2015
1019	7899 1790	1019	[https://t.co/...]	[https://t.co/...]	2.29E+09 UTC		[https://t.co/...]					15:13:16 2015
1020	11999 3170	1020	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					07:39:55 2015
1021	5027 200	1021	[https://t.co/...]	[https://t.co/...]	2.29E+09 UTC		[https://t.co/...]					06:30:44 2015
1022	11999 3170	1022	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					06:30:44 2015
1023	6715 976	1023	[https://t.co/...]	[https://t.co/...]	2.29E+09 UTC		[https://t.co/...]					07:02:52 2015
1024	6715 976	1024	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					07:02:52 2015
1025	6191 1095	1025	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					15:23:23 2015
1026	6619 1036	1026	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					15:31:34 2015
1027	6619 1036	1027	KHAMENIhamenei	KHAMENIhamenei	2.29E+09 UTC		#الله					15:31:34 2015

شکل ۴: نمونه مجموعه داده توییتر

ما از فیلدهای `text`, `target` برای انجام آزمایشات استفاده می کنیم.

جدول ۲. رتبه بندی جملات مجموعه داده توییتر

Ranked	-2	-1	0	+1	+2
Sentences	5394	93998	425084	294538	180986

به هر صور همانطور که گفتیم، دوربین ورزشی GoPro HD Hero بک وسیله‌ی اندۀ آل برای ثبت لحظات پر شمجان و خاطره انگیز ورزشکاران است.

However, as we said, the GoPro HD Hero Sport Camera is an ideal device for recording the most exciting and memorable moments of athletes.

با این حال، همانطور که گفتیم، Camera یک دستگاه ایده آل برای ضبط لحظات هیجان انگیز و به پادمانندی ورزشکاران است.

شکا ۳: لایه حساسی، آنلاین

2.4 اعتقاد کاوی

در اعتقاد کاوی، هم بازخوردهای مثبت و هم منفی مجموعه داده استفاده شده که نظرات فارسی کاربران در تويیتر می باشد را با استفاده از روش پیشنهادی CNN_WSD, LSTM_WSD رده بندی و درصد بازخورد مثبت و منفی نظرات کاربران در مورد هر یک از موضوعات استخراج می شود تا مشخص شود که آیا از نظر کاربران درصد بازخورد مثبت هریک از موضوعات بیشتر است یا درصد بازخورد منفی، درصد مثبت و منفی هر یک از موضوعات با توجه به مجموع فراوانی نسبی تکرار هر یک از لغات مثبت(زیبا، عالی، دوست داشتنی و غیره) و منفی(بد، رشت، نامناسب، افتضاح و غیره) مربوط به هر موضوع محاسبه می شود.

در مجموعه داده آموزشی هر جمله با ویژگی هایی مانند قطب، کلمات کلیدی و اهداف شرح داده می شود.

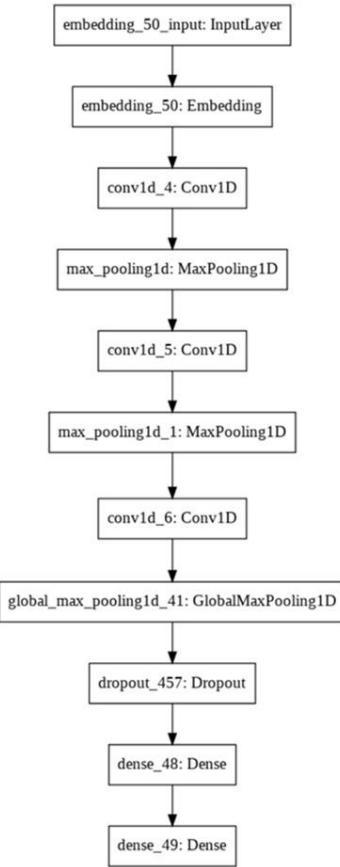
جدول ۱: مجموعه ای از احساسات رتبه بندی شده بر اساس قطبیت

Ranked	Emotion Class
-2	Furious
-1	Angry
0	Neutral
+1	Happy
+2	Delighted

قطبیت هر جمله از یک مجموعه E بین بازه $-2 \leq x \leq 2$ و -انتخاب شده است. E = {-2, -1, 0, +1, +2} که د. حدداً ۱ نمایش داده شده.

داده ۳.۴ پردازش

عملکرد یادگیری ماشین و یادگیری عمیق اغلب به اندازه و کیفیت داده‌های آموزشی بستگی دارد که جمع‌آوری آنها اغلب خسته کننده است (وی و زو، 2019). بنابراین، از چندین مجموعه داده متعدد استفاده شده است.



شکل ۶. ساختار لایه های در مدل های پیشنهادی

در این قسمت ساختار CNN مبتنی بر تعبیه کلمات (WSD) برای لایه های شبکه عصبی استفاده شده است، در روش پیشنهادی شبکه عصبی کانولوشن (CNN) است که یکی از موفق ترین ساختارهای شبکه های عصبی است این مدل برای داده های متنی خصوصاً در مسائل طبقه بندی متن نیز به خوبی عمل میکند تنظیمات CNN در روش استفاده شده در شکل ۷، قابل مشاهده است.

Layer (type)	Output Shape	Param #
embedding_1 (Embedding)	(None, 40, 300)	4500300
conv1d_1 (Conv1D)	(None, 40, 64)	57664
conv1d_2 (Conv1D)	(None, 40, 32)	6176
max_pooling1d_1 (MaxPooling1D)	(None, 13, 32)	0
conv1d_3 (Conv1D)	(None, 13, 16)	1552
conv1d_4 (Conv1D)	(None, 13, 8)	264
global_average_pooling1d_1 (GlobalAveragePooling1D)	(None, 8)	0
dense_1 (Dense)	(None, 1)	9

Total params: 4,565,965
Trainable params: 65,665
Non-trainable params: 4,500,300

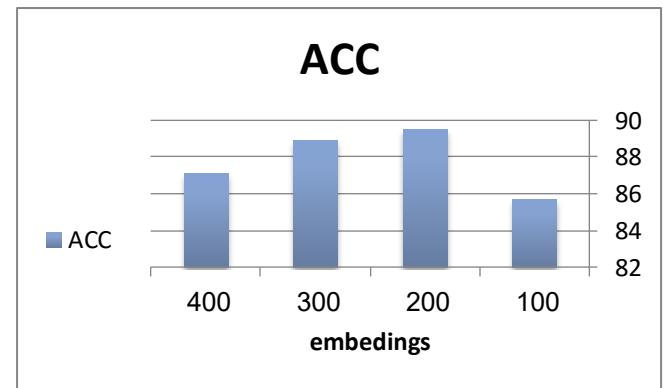
شکل ۷. ساختار لایه های در مدل های پیشنهادی CNN

تعداد جمله های تمام دسته ها ۱۰۰۰۰۰ می باشد که تعداد داده های هر دسته نیز در جدول ۲ مشخص شده است.(علی کرمی و همکاران، ۲۰۲۳)

۱.۵ پارامترها

از آنجا که هر متن به صورت مجموعه ای از کلمات تعبیه شده در آمده، در لایه اول مدل های شبکه عصبی خود، تعداد نرون ها به اندازه بیشترین طول جملات بر حسب کلمه است. در این مجموعه داده، طولانی ترین متن موجود شامل ۲۵۷ کلمه بوده و بنابراین در لایه اول ۲۵۷ نرون خواهیم داشت.

همانطور که در شکل ۵ نشان داده شده است، ما با تنظیمات مختلف مدل را آزمایش کرده ایم. در تعبیه کلمات به کمک Keras، در مدل های از قبل تعیین شده بهترین عملکرد با تعبیه کلمه embed_size = 300 بدست آمد. از آنجا که یادگیری تعبیه در خود شبکه عصبی صورت میگیرد این ابعاد گرام در نظر گرفته شده است. مدل اسکیپ گرام در محیط پایتون پایتون با استفاده از سیستم یادگیری عمیق کلب گوگل^۱ آموزش داده شد.



شکل ۵. تأثیر تعداد تعبیه کلمات بر عملکرد مدل LSTM_WSD با دو لایه پنهان از nh1 = 25 و nh2 = 24 نuron.

۲.۵ مدل ها

در این قسمت از ساختار LSTM مبتنی بر تعبیه کلمات برای لایه های شبکه عصبی استفاده شده است. نخستین ساختار حافظه طولانی کوتاه مدت دوطرفه (LSTM) است که بر پایه شبکه های عصبی بازگشتی طراحی شده و دوطرفه بودن آن امکان دریافت اطلاعات توسط گذشته و آینده را به لایه خروجی آن اضافه میکند. در شکل ۶ لایه های تعبیه شده برای این ساختار قابل مشاهده است.

3.5 نتایج

در آزمایشات ما، سه روش ارزیابی بر روی مجموعه داده توییتر در نظر گرفته می شود: دقت (Acc)، مساحت زیر منحنی (AUC) و F-Score. برای ارزیابی عملکرد مدل پیشنهادی، از روش k-fold cross validation استفاده شده که k برابر با ۱۰ می باشد.

جدول ۴. زمان آزمایشات مدل های مختلف روش پیشنهادی با پردازنده GPU

Experiments	TF-IDF		Word Embedding	
	CNN-WSD	LSTM-WSD	CNN-WSD	LSTM-WSD
Tweeter Dataset	2min 48s	23min 52s	8min 01s	10min 39s

جدول ۴ زمان پردازش مورد نیاز برای القاء مدل ها از مجموعه داده توییتر را نشان می دهد و شامل زمان CPU مورد نیاز در آزمایش ها است.

جدول ۴ نشان می دهد که استفاده از TF-IDF، به زمان محاسبه طولانی تری نسبت به استفاده از تعبیه کلمات (Word Embedding) نیاز دارد. این یکی دیگر از دلایلی است که تکنیک تعبیه کلمات را توصیه می کنیم. با این حال، LSTM با TF-IDF و هم با تعبیه کلمات وقت گیرترین الگوریتم است. در نهایت، خلاصه کلی از نتایج بدست آمده در آزمایشات را در زیر توضیح میدهیم:

دو مدل یادگیری عمیق (LSTM و CNN) با تفکیک شدت احساس کلمات برای انجام آزمایش های تجزیه و تحلیل احساسات استفاده شد. مشخص شد که مدل LSTM بهترین نتیجه بین زمان پردازش و دقت نتایج را ارائه می دهد. اگرچه مدل LSTM در هنگام استفاده از تعبیه کلمات از بالاترین درجه دقت برخوردار بود، اما زمان پردازش آن بیشتر از مدل CNN بود. مدل LSTM هنگام استفاده از تکییک TF-IDF موثر نیست و زمان پردازش بسیار بیشتر آن منجر به نتایجی می شود که بهتر نیستند.

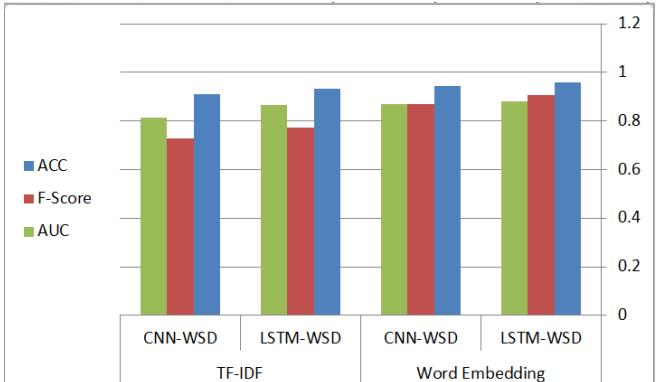
جدول ۵. مقایسه و ارزیابی نتایج روش پیشنهادی با سایر مدل های یادگیری عمیق

Model	AUC	Acc [%]	F-score	Testing time [s]
LSTM_WSD (this study)	88.13 ± 0.91	0.958 ± 0.011	0.907 ± 0.009	10.398 ± 0.226
CNN_WSD, (this study)	86.82 ± 0.91	0.943 ± 0.005	0.871 ± 0.006	8.012 ± 0.131
LSTM Alikarami et al.	84.05 ± 0.28	0.917 ± 0.003	0.841 ± 0.002	2.042 ± 0.128
CNN Alikarami et al.	84.29 ± 0.17	0.921 ± 0.001	0.844 ± 0.003	8.139 ± 0.286
DNN Alharbi et al.	84.14 ± 0.71	0.842 ± 0.002	0.828 ± 0.005	8.14 ± 0.31
Tree-LSTM	86.06 ±	0.867 ±	0.851 ±	4.15 ± 0.

جدول ۳. نتایج آزمایش های ACC و AUC برای توییتر مجموعه داده ها.

Experiments	TF-IDF		Word Embedding	
	CNN-WSD	LSTM-WSD	CNN-WSD	LSTM-WSD
ACC	0.910036	0.934178	0.943248	0.958863
F-Score	0.727000	0.772000	0.871000	0.907000
AUC	0.814408	0.864623	0.868279	0.881397

نتایج تعبیه کلمات برای روش LSTM_WSD : ACC برابر با ۰.۹۵۸ درصد و F-Score برابر با ۰.۹۰۷ و AUC برابر با ۰.۸۶۴ است و روش CNN_WSD با ACC برابر با ۰.۹۴۳ درصد و Score برابر با ۰.۸۷۱ و AUC برابر با ۰.۸۸۹ است. نتایج جدول ۳ نشان میدهد که استفاده از تعبیه کلمات برای تحلیل احساسات با یادگیری عمیق نتایج بهتری نسبت به IDF برای ارزیابی دقت (Acc)، مساحت زیر منحنی (AUC) و F-Score دارد.



شکل ۸- نمودار ارزیابی روش های یادگیری عمیق در مجموعه داده توییتر

نتایج شکل ۸ نشان میدهد، بهترین رفتار با ترکیب LSTM و تعبیه کلمات(Word embedding) نشان داده می شود و بالاترین مقادیر ACC، F_Score و AUC با تعبیه کلمات + LSTM داده شد. ما می توانیم تأیید کنیم که تعبیه کلمات یک تکنیک مناسب تر از TF-IDF برای انجام تجزیه و تحلیل احساسات است، پس از تجزیه و تحلیل نتایج مربوط به کیفیت پیش بینی ها، لازم است اطلاعاتی در مورد هزینه محاسباتی مرتبط با القاء مدل ها به دست آوریم.

برای مدل های تعبیه کلمات و TF-IDF را با روش-DNN (حساس به کلمه) مقایسه می کنیم. نتایج جدول ۶ نشان میدهد در رفتار هر دو مدل تعبیه کلمات و مدل مورد ارزیابی DNN-WSD برای تحلیل احساسات بر روی مجموعه داده توییتر عملکرد

جدول ۶. نتایج آزمایش های ACC، AUC و F-Score مجموعه داده ها.

Experiments	TF-IDF		Word Embedding	
	DNN-WSD	LSTM-WSD	DNN-WSD	LSTM-WSD
ACC	0.757757	0.934178	0.790962	0.958863
F-Score	0.763832	0.772000	0.788766	0.907000
AUC	0.764996	0.864623	0.788166	0.881397

مناسبی ندارد و مدل های LSTM و CNN عملکرد بهتری نسبت به DNN عملکرد بهتری دارند.

جدول ۴ و ۶ نشان می دهد که استفاده از TF-IDF ، به زمان محاسبه طولانی تری نسبت به استفاده از تعبیه کلمات نیاز دارد. این یکی دیگر از دلایلی است که تکنیک تعبیه کلمات را توصیه می کنیم. با این حال ، وقت گیرترین الگوریتم است ، هم با TF-IDF و هم با Word Embedding. با توجه به اینکه بهبود LSTM نسبت به CNN در مورد اخیر چندان قابل توجه نیست ، استفاده از این دو روش را می توان از نظر کاهش زمان و هزینه محاسباتی مناسب تر دانست. ما میدانیم که انواع مختلف مجموعه داده ها بر نتایج تجزیه و تحلیل احساسات متفاوت تأثیر می گذارد.

4.5 نتایج

در آزمایشات ما، سه روش ارزیابی بر روی مجموعه داده توییتر در نظر گرفته می شود: دقت (Acc) ، مساحت زیر منحنی (AUC) و F-Score. برای ارزیابی عملکرد مدل پیشنهادی، از روش k-fold cross validation استفاده شده که k برابر با ۱۰ می باشد. DNN و CNN برای به دست آوردن بازنمایی سطح معنایی جمله استفاده شدند. در این روش ، ابعاد حالت های پنهان / سلول روی ۳۰۰ تنظیم شده است که مربوط به تعداد کلمات تعبیه شده است. معماری CNN از لایه های حلقوی (convolutional layer) با پنجم فیلتر و حداقل لایه مخلوط max pooling تشکیل شده است. نمایش اسناد برای هر دو مدل به عنوان ترکیب بیان جملات با استفاده از GRU ساخته شد(تائگ و همکاران، ۲۰۱۵).

Model	AUC	Acc [%]	F-score	Testing time [s]
and Discourse-LSTM Kraus et al.	0.28	0.006	0.003	11
GRU, and hybrid approaches Do et al.	85.29 ± 0.16	0.851 ± 0.002	0.854 ± 0.006	11.2 ± 0.31
RNN Abid et al.	84.74 ± 0.91	0.850 ± 0.003	0.838 ± 0.008	9.16 ± 0.21
Coattention-LSTM + Location Yang et al.	87.52 ± 0.19	0.891 ± 0.002	0.871 ± 0.003	5.032 ± 0.18
Bi-LSTM Wu et al.	84.85 ± 0.06	0.871 ± 0.002	0.841 ± 0.003	3.042 ± 0.45

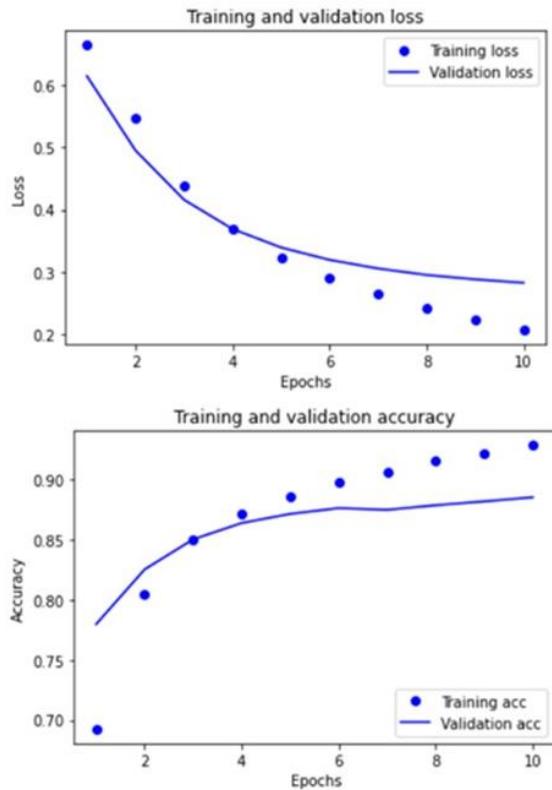
برای ارزیابی جامع اثربخشی مدل پیشنهادی، عملکرد آن را در مقابل مدل های موجود زیر مقایسه کردیم: LSTM در جدول ۵ روش های مختلف یادگیری عمیق از جمله Bi-LSTM، GRU، RNN، Tree-LSTM، DNN، CNN و Coattention-LSTM که از سال ها ۲۰۱۸ تا ۲۰۲۳ توسط محققین برای تحلیل احساسات بر روی مجموعه داده توییتر ارایه شده است با استفاده از نرم افزار پایتون برای مجموعه داده فارسی توییتر پیاده سازی و شبیه سازی شده اند و در حالت برابر ارزیابی شده است، با توجه به اینکه روش های یادگیری عمیق عملکرد بهتری نسبت به روش های یادگیری ماشین دارد ما فقط روش های پر کاربرد یادگیری عمیق را مورد ارزیابی و مقایسه قرار داده ایم.

نتایج جدول ۵ نشان میدهد، بهترین رفتار با ترکیب-LSTM و تعبیه کلمات نشان داده می شود و بالاترین LSTM + AUC با تعبیه کلمات CNN-WSD روش با تعبیه کلمات نیز نسبت به اکثر روش های مورد مقایسه نتایج بهتری داشته و زمان اجرای مدل CNN نسبت به LSTM بهتر می باشد، نتایج بدست آمده نشان می دهد روش های Bi Tree LSTM و LSTM زمان اجرای پایین تری نسبت به مدل های تعبیه کلمات و TF-IDF برای انجام تجزیه و تحلیل احساسات است، اما میزان دقت طبقه بندی این سه مدل به ترتیب ۹۱٪، ۸۶٪ و ۸۴٪ درصد است.

پس از تجزیه و تحلیل نتایج مربوط به کیفیت پیش بینی روش های مورد ارزیابی ما در جدول ۶ نتایج روش LSTM-WSD را

¹ Tang, D., Qin, B., Liu, T.

آزمون های معنی داری آماری که ما انجام دادیم راهی برای ارزیابی نتایج آزمون ها در اختیار ما قرار داد. سطح قابل اعتمادی که معمولاً برای نتایج استفاده می شود 95٪ است، همچنین به صورت $p = 0.05$ نوشته می شود و به عنوان سطح p شناخته می شود. همانطور که در شکل 13 نشان داده شده است، آزمون های معناداری آماری را برای آموزش و اعتبار سنجی اضافه کردیم.

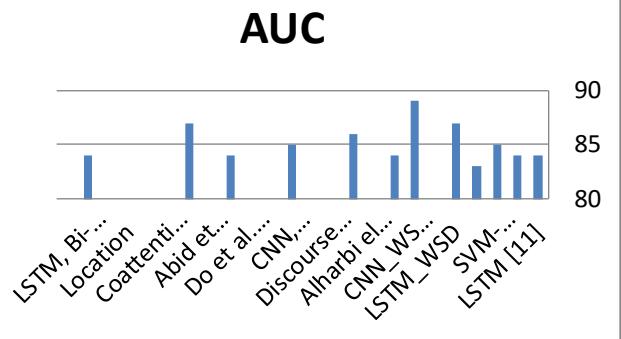


شکل ۱۲. نمودار دقت بر اساس دوره ها

شکل ۱۲ عملکرد مدل پیشنهادی LSTM+ WSD را بر اساس ۱۰ دوره نشان می دهد. حداقل میزان دقت برای ۱۰ تکرار ۹۳٪ و میزان خطای ۰.۱۸۹ برای Validation آموزش مدل تعییه کلمه است، اما در میزان دقت ۰.۸۸٪ و میزان خطای ۰.۲۸۱ است.

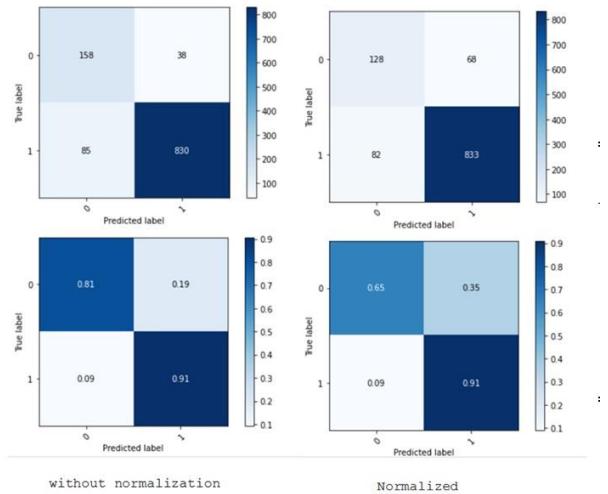
۵.۵ بحث

با توجه به جداول ۳ تا ۶ می توان نتیجه گرفت که Recall، دقت، F-score و AUC روش پیشنهادی LSTM و تعییه کلمه بهتر از سایر روش های ارزیابی شده است. این نتایج برای ترکیب LSTM و TF-IDF به ترتیب ۰.۷۷۶ و ۰.۵۶۹ و ۰.۶۴۱ است. نتایج به دست آمده در مقایسه با تعییه کلمات و TF-IDF برای مجموعه داده توییتر و سایر مجموعه های داده مبتنی بر روش LSTM نشان می دهد که نتایج تعییه کلمات در TF-IDF بهتر از LSTM است.



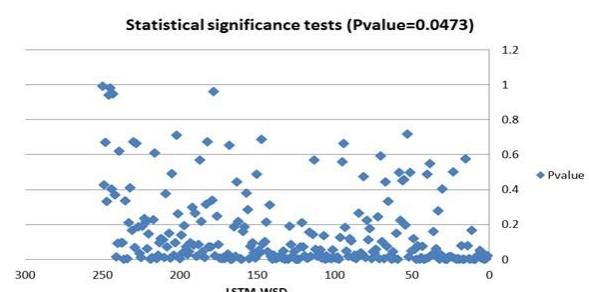
شکل ۹. مقایسه میزان AUC روش پیشنهادی نسبت به سایر روش ها

نتایج شکل ۹ نشان میدهد که میزان مساحت زیر منحنی AUC روش CNN_WSD برابر با LSTM_WSD است. ۸۶.۴۹ و ۸۸.۹۲



شکل ۱۰. نمودار سردرگمی برای LSTM+WSD

نمودار سردرگمی (Confusion) بر اساس سطح دقت مدل پیشنهادی LSTM و جاسازی کلمه برای مجموعه داده SentiPers طراحی شده است. این نمودار به دو صورت نرمال شده و بدون نرمال سازی طراحی شده است. به منظور ارزیابی عملکرد مدل LSTM و جاسازی کلمه، به صورت گرافیکی بر اساس ۱۰ دوره از مجموعه داده SentiPers نمایش داده می شود.



شکل ۱۱. نمودار Pvalue برای آزمون های معناداری آماری.

در زمینه سیاسی به دولت ها کمک می کند در زمینه های مختلف نظرات کاربران را در شبکه های اجتماعی تحلیل کنند و سیاست گذاری های خود را بر اساس دیدگاه و نظرات مردم انجام دهد.

در تحقیقات آینده، با بررسی انجمان های احساسات-کلمه(*word-sentiment*) و همچنین دیدگاه های کاربران در حوزه های مختلف می توان تجزیه و تحلیل کامل تری انجام داد. یکی از محدودیت های مدل پیشنهادی این است که در آن فقط ویژگی های محلی ضبط شده اند. استخراج ویژگی *n-gram* استفاده شده در این تحقیق، شbahت معنایی یا توانایی تمایز کلمات را در نظر نمی گیرد. بنابراین، نمایش های *n-gram* افزایش یافته (چن و همکاران، ۲۰۱۹) برای کاهش ابعاد و کمی بودن داده ها توصیه می شود. استفاده از یک روش انتخاب ویژگی مؤثر نیز ممکن است منجر به کاهش پیچیدگی محاسباتی و بهبود راندمان زمانی شود(باروشکا و هاجک، ۲۰۲۰) از طرح های جایگزین مبتنی بر تعییه نیز می توان استفاده کرد(عنان، ۲۰۱۹).

همچنین برای ترکیب CNN + جاسازی کلمه و DNN با دقت ۰.۷۹۱ Recall و ۰.۸۰۲ میزان دقت ۰.۷۸۸ FScore است.

نتایج بدست آمده نشان می دهد که روش تعییه کلمه و LSTM با دقت ۹۳ درصد و درصد خطای ۰.۱۸۹ نسبت به سایر روش های ارزیابی شده عملکرد بهتری دارند. اما زمان اجرای LSTM و تعییه کلمه بیشتر از CNN است.

در این مقاله محدودیت های پژوهشی وجود دارد. ابتدا، ما کلیدواژه های اصلی با فرکانس بالا را برای باور کاوی انتخاب کردیم و ممکن است برخی از کلیدواژه های مهم با فرکانس پایین نادیده گرفته شده باشند.

دوم: نتایج نشان می دهد که باور کاوی شامل رشته های بسیاری مانند علوم کامپیوتر، زبان شناسی و مهندسی برق است که نشان دهنده روند تحقیقات بین رشته ای است.

بنابراین، کارهای آینده باید از اسناد متعدد برای کشف ماهیت بین رشته ای استفاده کنند.

۶. نتیجه گیری

در این مطالعه، ما مدل پیشنهادی CNN، LSTM کارآمد با تفکیک شدت احساسات بر روی کلمه WSD برای استخراج نظر و اعتقاد کاوی ارائه داده ایم. ما با انجام آزمایشات گستره در مجموعه داده فارسی توییتر، عملکرد مدل را در مقایسه با نمایش های اولیه کلمه ثابت کردیم. ما مدل پیشنهادی را با روش های موجود یادگیری عمیق و سایر روش های یادگیری ماشین مقایسه کردیم. از این رو، اثربخشی مدل ارائه شده نشان داده شد.

نتایج آزمایشات نشان می دهد که تفکیک شدت شدت احساسات فقط بر اساس تعییه کلمات مؤثر هستند. ادغام WSD با N-gram، پیشرفت بیشتری را ارائه می دهد.

در این پژوهش، علاوه بر تحلیل احساسات بر روی مجموعه داده، احساسات کاربران در مقوله های مختلف سیاسی، اقتصادی، فرهنگی و علمی مورد تجزیه و تحلیل قرار گرفت تا تحلیل گران بتوانند جهت گیری فکری کاربران در آن زمینه و دیدگاه های مثبت و منفی را نشان دهند. این مطالعه از WSD کارآمد با تمایز شدت شدت احساس کلمات برای عقیده کاوی و تحلیل باور استفاده کرد. مدل پیشنهادی با روش های یادگیری عمیق موجود و سایر روش های یادگیری مашین برای نشان دادن اثربخشی مقایسه شد.

۶.۵ پیشنهادات و کاربردها

با توجه به اینکه حجم داده در شبکه های اجتماعی و وبسایت ها بالا است و بر اساس قطبیت کلمات تحلیل احساسات و اعتقاد کاوی بر روی جملات انجام می شود پیشنهاد می شود از روش های یادگیری عمیق برای افزایش دقت طبقه بندی در تحلیل احساسات و اعتقاد کاوی استفاده شود.

نتایج بدست آمده از این پژوهش نشان میدهد که عملکرد مدل یادگیری LSTM حساس به کلمه(WSD) نسبت به سایر مدل های یادگیری عمیق CNN، RNN و TF-IDF بهتر است. همچنین مدل تعییه کلمات عملکرد بهتری نسبت به برای تجزیه و تحلیل نظرات دارد.

به محققان پیشنهاد می شود بر روی مدل های یادگیری عمیق LSTM و کانولوشن + تعییه کلمات و مدل های ترکیبی بر اساس حساسیت به کلمات و دیدگاه کاربران فعالیت کنند.

تحلیل احساسات و اعتقاد کاوی داده های شبکه های اجتماعی باعث درک نظرات کاربران شده و کاربردهای گسترده ای در تصمیم گیری و سیاست گذاری ها دارد و در زمینه های مختلف سیاسی، اجتماعی، اقتصادی، فرهنگی و ورزشی کاربرد دارد.

به عنوان مثال در زمینه اقتصادی تحلیل نظرات کاربران بر روی محصولات می تواند به فروشگاه ها و تولید گنندگان کمک کند تا نظرات مشتریان را تحلیل کند تا سیاست گذاری و تصمیم های مناسب را جهت افزایش جذب مشتریان انجام دهند.

مراجع:

14. Cach Dang, N., Moreno-García, M.N. and De la Prieta, F., (2020), *Sentiment Analysis Based on Deep Learning: A Comparative Study*, *Electronics* 2020, 9, 483; doi:10.3390/electronics9030483.
15. Catal, C., Nangir, M.: A sentiment classification model based on multiple classifiers. *Appl. Soft Comput.* 50, 135–141 (2017)
16. Chen, X., Xue, Y., Zhao, H., Lu, X., Hu, X., Ma, Z.: A novel feature extraction methodology for sentiment analysis of product reviews. *Neural Comput. Appl.* 31(10), 6625–6642 (2019)
17. Chen, Z.; Liu, B. Lifelong machine learning. *Synth. Lect. Artif. Intell. Mach. Learn.* 2018, 12, 1–207. [CrossRef]
18. Dashtipour, K. et al., (2018). *Exploiting Deep Learning for Persian Sentiment Analysis*. s.l., s.n.
19. Dastgheib, M.B. and Koleini, S., (2019), *Persian Text Classification Enhancement by Latent Semantic Space*, *International Journal of Information Science and Management*, Vol 17(1), pp. 33-46.
20. Do, H.H., Prasad, P.W.C., Maag, A., Alsadoon, A.: Deep learning for aspect-based sentiment analysis: a comparative review. *Expert Syst. Appl.* 118, 272–299 (2019)
21. Do, H.H.; Prasad, P.; Maag, A.; Alsadoon, A.J. Deep Learning for Aspect-Based Sentiment Analysis: A Comparative Review. *Expert Syst. Appl.* 2019, 118, 272–299. [CrossRef]
22. Du, C. and Huang, L., (2018), *Text Classification Research with Attention-based Recurrent Neural Networks*, *International Journal of Computers Communications & Control*, ISSN 1841-9836, 13(1),pp. 50-61.
23. Fang, Y., Tan, H. and Zhang, J., (2018), *Multi-Strategy Sentiment Analysis of Consumer Reviews Based on Semantic Fuzziness*, *IEEE Translations and content mining are permitted for academic research only*, Vol 6, pp.20625-20631.
24. Ferrara, E., Varol, O., Davis, C., Menczer, F., and Flammini, A., (2016), “The rise of social bots,” *Commun. ACM*, vol. 59, no. 7, pp. 96–104.
25. H. Alikarami, A.M. Bidgoli and M. Sadeghzadeh, *Text mining of Persian texts based on Cellular Learning Automata and optimizing parameters of SVM*, 4th international congress on engineering,
1. A. Onan, *Sentiment analysis on product reviews based on weighted word embeddings and deep neural networks*. *Concurrency and Computation: Practice and Experience*, 33(23), e5909, 2020.
2. A. Onan, *Bidirectional convolutional recurrent neural network architecture with group-wise enhancement mechanism for text sentiment classification*, *Journal of King Saud University - Computer and Information Sciences*, Volume 34, Issue 5, Pages 2098-2117, 2022.
3. Abid, F.; Alam, M.; Yasir, M.; Li, C.J. *Sentiment analysis through recurrent variants latterly on convolutional neural network of Twitter*. *Future Gener. Comput. Syst.* 2019, 95, 292–308.
4. Alharbi, A.S.M.; de Doncker, E. *Twitter sentiment analysis with a deep neural network: An enhanced approach using user behavioral information*. *Cogn. Syst. Res.* 2019, 54, 50–61.
5. Alikarami, H. and Khadem, F., (2016), *Data Mining Using Genetic Algorithms and Cellular Learning Automata Based on Factor Analysis and Cluster Analysis*, *1st International Conference on New Research Achievements in Electrical and Computer Engineering*, Tehran, Iran.
6. Available online: <http://alt.qcri.org/semeval2017/> (accessed on 12 March 2020).
7. Available online: <http://help.sentiment140.com/site-functionality> (accessed on 12 March 2020).
8. Available online: <http://www.cs.cornell.edu/people/pabo/movie-review-data/> (accessed on 12 March 2020).
9. Available online: <https://www.kaggle.com/c/word2vec-nlp-tutorial/data> (accessed on 12 March 2020).
10. Available online: <https://www.kaggle.com/crowdflower/twitter-airline-sentiment> (accessed on 12 March 2020).
11. Barushka, A., Hajek, P.: *Spam detection on social networks using cost-sensitive feature selection and ensemble-based regularized deep neural networks*. *Neural Comput. Appl.* 1–19 (2020)
12. Basiri, M. E., Nilchi, A. R. N. & Ghassem-aghaee, N., (2014). *A Framework for Sentiment Analysis in Persian*.
13. Basiri, M.E. and kabiri, A., (2018), *Words Are Important: Improving Sentiment Analysis in the Persian Language by Lexicon Refining*,

36. Kim, Y., 2014. *Convolutional Neural Networks for Sentence Classification*. Doha, Qatar, s.n.
37. Kraus, M.; Feuerriegel, S. Sentiment analysis based on rhetorical structure theory: Learning deep neural networks from discourse trees. *Expert Syst. Appl.* 2019, 118, 65–79.
38. Kumar, S.; Gahalawat, M.; Roy, P.P.; Dogra, D.P.; Kim, B.-G.J.E. Exploring Impact of Age and Gender on Sentiment Analysis Using Machine Learning. *Electronics* 2020, 9, 374.
39. LeCun, Y., Bengio, Y. & Hinton, G., 2015. Deep learning. *Nature*, Volume 521, pp. 436–444.
40. Li, L.; Goh, T.-T.; Jin, D. How textual quality of online reviews affect classification performance: A case of deep learning sentiment analysis. *Neural Comput. Appl.* 2018, 1–29.
41. Liu, B., 2012. *Sentiment Analysis and Opinion Mining. Synthesis lectures on human language technologies*, pp. 1–167.
42. Maas, A.L.; Daly, R.E.; Pham, P.T.; Huang, D.; Ng, A.Y.; Potts, C. Learning word vectors for sentiment analysis. In *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies-Volume 1*, Portland, OR, USA, 19–24 June 2011; pp. 142–150.
43. Marzieh Fadaee, Arianna Bisazza, and Christof Monz. 2017. Data Augmentation for Low-Resource Neural Machine Translation. *arXiv e-prints*, page arXiv:1705.00440.
44. Mousavirad, S.J. and Ebrahimpour-Komleh, H., (2014), Wrapper Feature Selection using Discrete Cuckoo Optimization Algorithm, *Austrian E-Journals of Universal Scientific Organization*, Vol. 4(11), Apr, pp. 709-721.
45. Onan, A.: Deep learning based sentiment analysis on product reviews on Twitter. In: Younas, M., Awan, I., Benbernou, S. (eds.) *Innovate-Data 2019. CCIS*, vol. 1054, pp. 80–91. Springer, Cham (2019). https://doi.org/10.1007/978-3-030-27355-2_6
46. Piryani, R., Madhavi, D. and Singh, V.K., (2017), “Analytical mapping of opinion mining and sentiment analysis research during 2000–2015,” *Information Processing & Management*, vol. 53, no. 1, pp. 122–150.
47. Qiu, L. and Li, J., (2018), Sentiment analysis of short texts in microblog based on dependency parsing, *springer: Cluster Computing*, Volume 21, Issue 1, pp 985-995.
48. Roustaei, A. and Rastegari, H., (2018), Persian question classification using headword and semantic features, *IEEE technology & applied science*, New Zealand-Auckland, 2019.
26. H. Alikarami, A. M. Bidgoli and H. H. S. Javadi, (2023), "Belief Mining in Persian Texts Based on Deep Learning and Users' Opinions (revised December 2022)," in *IEEE Transactions on Affective Computing*, doi: 10.1109/TAFFC.2023.3288407.
27. Hajek P., Barushka A., Munk M. (2020) Opinion Mining of Consumer Reviews Using Deep Neural Networks with Word-Sentiment Associations. In: Maglogiannis I., Iliadis L., Pimenidis E. (eds) *Artificial Intelligence Applications and Innovations. AIAI 2020. IFIP Advances in Information and Communication Technology*, vol 583. Springer, Cham. https://doi.org/10.1007/978-3-030-49161-1_35.
28. Hassan, A. and Mahmood, A., (2018), Convolutional Recurrent Deep Learning Model for Sentence Classification, *IEEE*, Vol 6, pp. 13949 – 13957.
29. Hosseini, P. et al., 2018. SentiPers: A Sentiment Analysis Corpus for Persian. *arXiv*.
30. Jason Wei and Kai Zou. 2019. EDA: Easy Data Augmentation Techniques for Boosting Performance on Text Classification Tasks. *arXiv e-prints*, page arXiv:1901.11196.
31. Jeong, B.; Yoon, J.; Lee, J.-M. Social media mining for product planning: A product opportunity mining approach based on topic modeling and sentiment analysis. *Int. J. Inf. Manag.* 2019, 48, 280–290. [CrossRef]
32. Johnson, R., Zhang, T.: Effective use of word order for text categorization with convolutional neural networks. In: *Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pp. 103–112 (2015)
33. Joseph Turian, Lev-Arie Ratinov, and Yoshua Bengio. 2010. Word representations: A simple and general method for semi-supervised learning. In *Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics*, pages 384–394, Uppsala, Sweden. Association for Computational Linguistics.
34. K. Wang and X. Wan, Counterfactual Representation Augmentation for Cross-Domain Sentiment Analysis. *IEEE Transactions on Affective Computing*, 2022.
35. Kausar, S., Huahu, X., Shabir, M.Y., Ahmad, W.: A sentiment polarity categorization technique for online product reviews. *IEEE Access* 8, 3594–3605 (2019)

59. Urologin, S., (2018), *Sentiment Analysis Visualization and Classification of Summarized News Articles: A Novel Approach*, (*IJACSA International Journal of Advanced Computer Science and Applications*, Vol. 9, No. 8, pp. 616-624.
60. Wang, Y.; Wang, M.; Xu, W. A sentiment-enhanced hybrid recommender system for movie recommendation A big data analytics framework. *Wirel. Commun. Mob. Comput.* 2018, 2018. [CrossRef]
61. Woolley, S.C., (2016), “Automating power: Social bot interference in global politics,” *First Monday*, vol. 21, no. 4.
62. Wu, C.; Wu, F.; Wu, S.; Yuan, Z.; Liu, J.; Huang, Y. Semi-supervised dimensional sentiment analysis with variational autoencoder. *Knowl. Based Syst.* 2019, 165, 30–39.
63. Y. Wang, M. Wang, W. Xu, A sentiment-enhanced hybrid recommender system for movie recommendation A big data analytics framework. *Wirel. Commun. Mob. Comput.* 2018, 2018.
64. Yang, C.; Zhang, H.; Jiang, B.; Li, K.J. Aspect-based sentiment analysis with alternating coattention networks. *Inf. Process. Manag.* 2019, 56, 463–478. [CrossRef]
65. Yao, Q.Z., Song, Z.L. and Peng, C., (2011), *Research on text categorization based on LDA*, *Computer Engineering and Applications*, Vol 47(13), pp. 150–153.
- Journal of Theoretical and Applied Information Technology, Vol 96(21), pp. 7206-7214.
49. S. Mai, Y. Zeng, S. Zheng and H. Hu, (2022). Hybrid contrastive learning of tri-modal representation for multimodal sentiment analysis. *IEEE Transactions on Affective Computing*.
50. Schmitt, M.; Steinheber, S.; Schreiber, K.; Roth, B. Joint Aspect and Polarity Classification for Aspect-based Sentiment Analysis with End-to-End Neural Networks. *arXiv* 2018, *arXiv:1808.09238*.
51. Shams, M., Shakery, A. & Faili, H., (2012). A non-parametric LDA-based induction method for sentiment analysis. *Shiraz, Iran*, s.n.
52. Shayaa, S. and et al., (2018), *Sentiment Analysis of Big Data: Methods, Applications, and Open Challenges*, *IEEE*. Translations and content mining are permitted for academic research only, Vol 6, pp. 37807-37827.
53. Singh, V.K.; Mukherjee, M.; Mehta, G.K. Combining collaborative filtering and sentiment classification for improved movie recommendations. In *Proceedings of the International Workshop on Multi-disciplinary Trends in Artificial Intelligence*, Hyderabad, India, 7–9 December 2011; pp. 38–50.
54. Singhal, P.; Bhattacharyya, P. *Sentiment Analysis and Deep Learning: A Survey*; Center for Indian Language Technology, Indian Institute of Technology: Bombay, Indian, 2016.
55. Sohrabi, M.K. and Roshani, R., (2017), Frequent itemset mining using cellular learning automata, *Computers in Human Behavior*, Vol 68, pp. 244-253.
56. Stai, E.; Kafetzoglou, S.; Tsiropoulou, E.E.; Papavassiliou, S.J. A holistic approach for personalization, relevance feedback & recommendation in enriched multimedia content. *Multimed. Tools Appl.* 2018, 77, 283–326.
57. T. Turki and S.S. Roy, *Novel Hate Speech Detection Using Word Cloud Visualization and Ensemble Learning Coupled with Count Vectorizer*. *Applied Sciences*, 12(13), 6611, 2022.
58. Tang, D., Qin, B., Liu, T.: Document modelling with gated recurrent neural network for sentiment classification. In: *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, pp. 1422–1432 (2015)

The belief of Persian text mining based on deep learning with emotion-word separation

Abstract:

Belief analysis or the classification of texts based on the feelings and opinions of users on websites and social media helps people, companies and organizations to make important decisions. Belief mining includes a system for analyzing people's opinions and feelings about an entity such as products, people, organizations, according to the opinions, messages and tweets of users in social media.

In this article, the belief analysis of Persian texts based on the messages, comments and tweets of users in social media and websites of 4 datasets using two deep learning methods, CNN, LSTM, taking into account the sense of the word, in two poles, positive and negative with intervals. 2- and 2+ are classified. In the proposed method, first the process of data pre-processing based on character to number conversion, removing the list of extra words and multi-word analysis is done, then for belief analysis and classification of Persian texts CNN, LSTM machine learning algorithm with word sense separation (WSD) is used to Recognize the intensity of emotions according to the words. We call the proposed model CNN_WSD and LSTM_WSD.

In the proposed method, the Persian Twitter dataset is used for evaluation and then it is compared with other machine learning and deep learning methods, DNN, CNN, LSTM, in the implementation of this method, python software is used. The accuracy rate of the proposed method for LSTM-WSD and CNN-WSD is 95.8 and 94.3%, respectively.

Keywords: Belief mining, natural language processing (NLP), deep learning, text mining.