

# **The Belief of Persian Text Mining Based on Deep Learning with Emotion-Word Separation**

**Hossein Alikarami<sup>1</sup>, Amir Massoud Bidgoli<sup>2\*</sup>, Hamid Haj Seyed Javadi<sup>3</sup>**

<sup>1</sup> Department of Computer Engineering, North Tehran Branch, Islamic Azad University, Tehran, Iran

<sup>2</sup> Department of Computer Engineering, North Tehran Branch, Islamic Azad University, Tehran, Iran

<sup>3</sup> Department of Mathematics and Computer Science, Shahed University, Tehran, Iran

Received: 29 June 2023, Revised: 17 November 2023, Accepted: 12 December 2023

Paper type: Research

## **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, and 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 four 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.

---

\* Corresponding Author's email: DrBidgoli@gmail.com; am\_bidgoli@iau-tnb.ac.ir

## اعتقادیابی متون فارسی بر اساس یادگیری عمیق با تفکیک احساس-کلمه

حسین علی کرمی<sup>۱</sup>، امیرمسعود بیدگلی<sup>۲</sup>، حمید حاج سیدجوادی<sup>۳</sup>  
<sup>۱</sup> گروه مهندسی کامپیوتر، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران  
<sup>۲</sup> گروه مهندسی کامپیوتر، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران  
<sup>۳</sup> گروه ریاضی و علوم کامپیوتر، دانشگاه شاهد، تهران، ایران

تاریخ دریافت: ۱۴۰۲/۰۴/۰۸ تاریخ بازبینی: ۱۴۰۲/۰۸/۲۶ تاریخ پذیرش: ۱۴۰۲/۰۹/۲۱  
نوع مقاله: پژوهشی

### چکیده

اعتقادکاوی یا طبقه‌بندی متون بر اساس احساس و عقیده کاربران در وبسایت‌ها 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 توییت‌های کاربران در رسانه‌های اجتماعی می‌باشد. در این مقاله اعتقادکاوی متون فارسی بر اساس پیام‌ها، نظرات و توییت‌های کاربران در رسانه اجتماعی با استفاده از دو روش یادگیری عمیق LSTM, CNN با در نظر گرفتن شدت احساس کلمات و دیدگاه کاربران، در دو قطب مثبت و منفی با بازه ۲- و ۲+ طبقه‌بندی 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 CNN و LSTM 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 طبقه‌بندی متون در چهار دسته سیاسی، اجتماعی، اقتصادی و فرهنگی تشخیص داده می‌شود. ما مدل پیشنهادی را CNN\_WSD و LSTM\_WSD می‌نامیم. در این مقاله از مجموعه داده فارسی توییت برای ارزیابی و مقایسه روش پیشنهادی با سایر روش‌های یادگیری ماشین و یادگیری عمیق از جمله LSTM, CNN, DNN استفاده شده، پیاده‌سازی این روش با نرم‌افزار پایتون انجام شده است. میزان دقت روش پیشنهادی برای LSTM-WSD و CNN-WSD به ترتیب 95.8 و 94.3 درصد است.

کلید واژگان: اعتقادکاوی، پردازش زبان طبیعی (NLP)، یادگیری عمیق، متن کاوی.

## ۱- مقدمه

بر اساس دیدگاه آنها در دسته‌های مثبت و منفی بین بازه  $+2$  و  $-2$  تحلیل می‌کند.

در اعتقادکاوی و تحلیل احساسات بر اساس نظرات کاربران 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 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 رده‌بندی 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 ارائه 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 بدنه اصلی اسناد آموزشی با روش اسکپ‌گرام<sup>۱</sup> مشخص می‌شود و با مقایسه کلمات با واژگان، شدت احساسات آن مشخص می‌شود و در دسته‌های مثبت و منفی در بازه  $+2$  و  $-2$  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.

تحلیل احساسات که همچنین نظرکاوی نامیده می‌شود، بخشی از مطالعات است که به تحلیل عقاید، احساسات و نگرش‌های مردم درباره موجودیت‌هایی همچون محصولات، سرویسها، سازمان‌ها، افراد، رخدادها و موضوعات خاص می‌پردازد [۱].

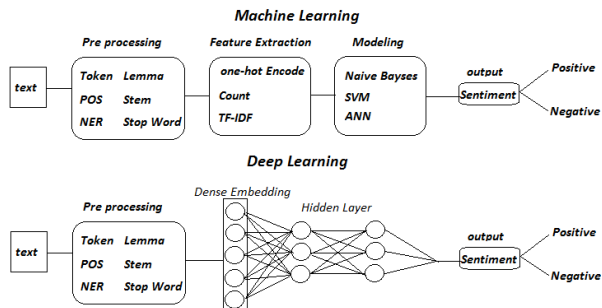
در فعالیت‌هایی که تاکنون بر روی متون فارسی انجام شده اغلب به طبقه‌بندی متون با توجه به زمینه و حوزه مورد مطالعه پرداخته شده است، در زمینه اعتقادکاوی و تحلیل احساسات بر روی نظرات و متون فارسی پیشرفت چشمگیری انجام نشده، در فعالیت‌هایی که تاکنون انجام شده اغلب بدون در نظر گرفتن معنا، شدت حساسیت کلمات و دیدگاه کاربران و کلمات اضافی فقط نظرات را در دو گروه مثبت و منفی طبقه‌بندی 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 دسته‌بندی شده و برای هر قطب شدت احساسات بین بازه  $-2$  و  $+2$  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 محققان 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 متنی و تحلیل احساسات، بر روی داده کاوی و طبقه‌بندی 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 داده‌اند 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

<sup>۱</sup> Skip-gram

احساسات بین دو رویکرد یادگیری ماشین و یادگیری عمیق را 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).

یادگیری عمیق شامل شبکه عصبی عمیق (DNN)، شبکه عصبی حلقوی (CNN)، شبکه عصبی مکرر (RNN) و LSTM است [۲].

شبکه عصبی عمیق: یک شبکه عصبی با بیش از دو لایه است که برخی از آن‌ها لایه‌های پنهان هستند. شبکه‌های عصبی عمیق از مدل‌سازی 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 توصیه‌کننده 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 فعال‌سازی در لایه پنهان است. سایر روش‌های یادگیری عمیق در [۳] بیان شده است.

### ۳- 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

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 پرداخته‌ایم. 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، 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 تصمیم‌گیری 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 زمینه‌ای 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 CNN\_WSD و LSTM\_WSD ارائه شده، در بخش پنجم پردازش داده‌ها، در بخش ششم نتایج و آزمایشات روش پیشنهادی و مقایسه با سایر روش‌ها و سپس به نتیجه‌گیری پرداخته شده است.

### ۲- 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

گرفته شده است [۸]. در مقایسه روش تعبیه کلمات با مدل کیف واژه<sup>۱</sup>، روش تعبیه کلمات در مدل سازی متن کلمه و معنی کلمه نیز مؤثر است. بعد از تولید اسناد مناسب، می توان از مدل های مختلف شبکه عصبی و سایر روش های یادگیری ماشین، مانند ماشین های بردار پشتیبان، برای تولید کلمات تعبیه شده و طبقه بندی عقاید استفاده کرد [۹].

یکی از اولین پژوهش های صورت گرفته در زمینه نظر کاوی برای زبان فارسی مربوط به گردآوری مجموعه داده ای با نام PersianClues است. این پژوهش با استفاده از یک روش ابتکاری بدون ناظر به تحلیل احساسات می پردازد. در واقع تغییری که در این روش صورت گرفته اضافه کردن مجموعه کلمات حاوی بار معنایی به عنوان بردار ویژگی ها در مرحله یادگیری [۱۰]، پژوهش دیگری نیز تحت عنوان ایجاد یک سیستم نظر کاوی با استفاده از الگوریتم های ناظر انجام گرفته است. در گام نخست آن، یک لغتنامه احساس برای زبان فارسی به کمک شبکه واژگانی فارسی موجود، فارسی 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 [۱۱].

یکی از روش های اعتقاد کاوی و تحلیل احساسات بر روی متون فارسی، تحلیل احساسات کاربران بر اساس دیدگاه آنها است که با روش های یادگیری عمیق CNN، DNN و LSTM و تکنیک تعبیه کلمات<sup>۲</sup> و TF-IDF به آن پرداخته شده بر اساس نتایج این مقاله روش تعبیه کلمات<sup>۳</sup> با LSTM برای تحلیل احساسات مبتنی بر دیدگاه کاربران نتایج بهتری را داشته است [۳].

دو و هانگ<sup>۴</sup> مقاله ای تحت عنوان تحقیقات طبقه بندی متن با شبکه های عصبی مکرر مبتنی بر توجه را ارائه دادند که روش پیشنهاد شده در این مقاله مزایای هر دو روش را در نظر می گیرد. با استفاده از یک سازوکار توجه بر روی یادگیری وزن برای هر کلمه استفاده می شود. در این روش، کلمات کلیدی وزن بیشتری خواهند داشت و کلمات رایج وزن کمتری خواهند داشت. بنابراین، در نظر کاوی متون و اعتقادیابی نه تنها همه کلمات را در نظر می گیرد بلکه توجه بیشتری به کلمات کلیدی نیز می کند [۱۲].

یکی دیگر از پژوهش های صورت گرفته در زبان فارسی تحت عنوان

طور خودکار پرداخته شد. نتایج نشان می دهد که در زمینه حجم داده های بزرگ، دقت طبقه بندی آن بسیار بهتر از تعریف قوانین است. بنابراین تحقیقات کنونی بر طبقه بندی خودکار متون با الگوریتم های هوش مصنوعی متمرکز است [۴].

طبقه بندی متون یکی از وظایف اصلی یادگیری ماشین است. هدف آن طراحی الگوریتم های مناسب برای استخراج ویژگی ها و طبقه بندی متون به صورت خودکار است. در گذشته، اساساً از طبقه بندی کلمات کلیدی و طبقه بندی سنتز معنایی با شبکه عصبی استفاده می شد.

محققان در طول سال های ۲۰۰۰-۲۰۱۵ به ارزیابی و مقایسه روش های تجزیه و تحلیل احساسات و متن کاوی پرداخته اند [۵]. در زمینه تحلیل های احساسی مانند استخراج احساسات، نظر کاوی، استخراج نظرات و اعتقاد کاوی، روش هایی 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، تکنیک های یادگیری ماشین سنتی نمی توانند نظرات را به خوبی نشان دهند. برای رفع این مشکل روش تحلیل احساسات با فاز معنایی برای حل مسئله پیشنهاد شده است [۶].

مطالعه افکار عمومی می تواند اطلاعات ارزشمندی را در اختیار ما قرار دهد. تجزیه و تحلیل احساسات در شبکه های اجتماعی، مانند توییتر یا فیس بوک، به ابزاری قدرتمند برای تحلیل نظرات کاربران تبدیل شده و کاربردهای گسترده ای دارد. با این حال، چالش هایی در صحت تحلیل احساسات در پردازش زبان طبیعی (NLP) پیش آمده. در سال های اخیر نشان داده شده است که مدل های یادگیری عمیق یک راه حل امیدوارکننده برای چالش های تحلیل احساسات و اعتقاد کاوی است. در مطالعاتی مانند قطبیت احساسات که از یادگیری عمیق برای حل مشکلات تحلیل احساسات استفاده شده است، مدل هایی با استفاده از فرکانس سند، فرکانس معکوس (TF-IDF) و تعبیه کلمه بر روی یک سری مجموعه داده ها اعمال شده اند [۲].

با توجه به ویژگی های مورد استفاده برای بهره برداری از نظرات مصرف کننده، مدل کیف واژه ها بیانگر سند سنتی است که در آن فرکانس های کلمه برای هر کلمه (عبارت) در واژگان محاسبه می شود [۷]. با این حال، این رویکرد منجر به بازنمایی اسناد پراکنده در ابعاد بالا می شود، علاوه بر این، این روش معنی کلمه را نادیده می گیرد. برای غلبه بر این مشکلات، روش تعبیه کلمات به جای تک کلمات معرفی شده اند، که یک زمینه کوتاه در نظر

<sup>1</sup> Bag-of-Words

<sup>2</sup> Word Embedding

نیستند و منجر به افزایش خطاها در طبقه‌بندی می‌شوند، ویژگی‌های بهینه انتخاب می‌شوند و سپس این ویژگی‌ها به ماشین یادگیری داده می‌شود [۱۷].

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 [۱۸]، او یک رویکرد مجموعه‌ای برای انتخاب ویژگی ارائه کرد، که چندین لیست ویژگی‌های فردی را که با روش‌های مختلف انتخاب ویژگی به دست آمده‌اند جمع می‌کند تا زیر مجموعه ویژگی‌های قوی‌تر 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 [۱۹].

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 [۲۰].

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 بخشند [۲۱].

سیجی مای و همکاران یک چارچوب جدید با نام HyCon برای یادگیری متضاد ترکیبی نمایش سه وجهی برای احساسات چندوجهی ارائه کردند [۲۲].

ترکی و روی یک روش تشخیص سخنان منفی را با استفاده از تجسم ابری کلمه و یادگیری گروهی با بردار شمارنده ارائه کردند، آنها از یک چارچوب محاسباتی استفاده کردند که تکنیک‌های تقویت داده‌ها را برای بازنمایی و عملکرد بهتر استفاده کردند [۲۳].

#### ۴- روش پیشنهادی یادگیری عمیق با تفکیک شدت احساس کلمات

در روش پیشنهادی مجموعه داده توپیتر 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  $+2$  و  $-2$  نمایش داده شده‌اند که عدد کوچکتر نشانگر قطبیت کمتر (بار منفی بیشتر) است.

هدف اصلی در متن‌کاوی، تحلیل احساسات کاربران بر اساس

بهربرداری 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 نموده‌اند [۱۳].

بصیری و کبیری مقاله‌ای تحت عنوان بهبود تجزیه و تحلیل احساسات و اعتقادیابی در زبان فارسی با استفاده از اصلاح واژگان را ارائه دادند، که هدف از تجزیه و تحلیل احساسات 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 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 دقت روش‌های موجود مبتنی بر واژگان پایین‌تر از زبان‌های دیگر است [۱۴].

اورولاگین<sup>۲</sup> مقاله‌ای تحت عنوان یک رویکرد جدید برای تجزیه و تحلیل احساسات و تجسم فکری و طبقه‌بندی خلاصه اخبار ارائه 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. خلاصه‌سازی متن و تحلیل احساسات بر روی اخبار بی بی سی انجام شده است. روش خلاصه‌سازی 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 [۱۵].

کیویو و لی<sup>۳</sup> مقاله‌ای تحت عنوان تجزیه و تحلیل احساسات متن کوتاه در میکرو بلاگ براساس تجزیه وابستگی را ارائه دادند، این روش برای حل مشکلات ارتباط بین کلمات عاطفی و اصلاح‌کننده 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 [۱۶]. همچنین با در نظر گرفتن معنای کلمات در نظرکاوی، با توجه به اینکه برخی از ویژگی‌های انتخابی مناسب

<sup>1</sup> Sentiment Analysis

<sup>2</sup> Siddhaling Urologin

<sup>3</sup> Lirong Qiu, Jie Li

c نمایانگر شعاع پنجره متن است (چند کلمه اطراف را در نظر می‌گیریم و  $p(\omega + 1|\omega_t)$  احتمال کلمه خروجی با توجه به کلمات ورودی محاسبه شده با استفاده از الگوریتم سلسله مراتبی (softmax) است.

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

جایی که  $\omega_0$  و  $\omega I$  به ترتیب کلمات ورودی و خروجی هستند.  $v_{\omega}$  و  $v'_{\omega}$  به ترتیب نشانگرهای بردار کلمات ورودی و خروجی را نشان می‌دهند.  $n(\omega, j)$  گره زام در درخت باینری است.  $L(\omega)$  طول مسیر در درخت است.  $ch(n)$  یک گره فرزند را نشان می‌دهد.  $\sigma(x)$  یک تابع عملکرد سیگموئیدی را مشخص می‌کند.

در صورتی که اگر  $x$  صحیح باشد  $[X] = 1$ ؛ در غیر این صورت  $[X] = -1$ .

برای به دست آوردن بازنمایی سند برای لایه بعدی در معماری CNN\_WSD, LSTM\_WSD، میانگین مقادیر بردارها از ماتریس وزن تعبیه 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 می‌شود به یک واژگان واحد اعتماد نکنید. علاوه بر این، ترکیبی از شاخص‌های احساسات مبتنی بر واژگان، مشکل حساسیت به عقاید غیرمستقیم را که معمولاً در مدل‌های یادگیری ماشین وجود دارد، غلبه می‌کند. برای محاسبه قطبیت احساسات، از دو واژگان دست‌ساز کلمات مثبت و منفی استفاده کردیم [۱۴].

یکی از کمبودهای این واژگان این است که وزن مساوی بدون توجه به شدت احساس آنها به همه کلمات اختصاص می‌یابد. برای پرداختن به این مسئله، ما شاخص‌های 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 می‌توان برای هر واژگان محاسبه کرد. علاوه بر این، ترکیب چندین واژگان، پوشش واژگان بالاتری را تضمین می‌کند [۲۵].

برای به دست آوردن جایگاه n-gram، وزن هر n-gram به شرح زیر محاسبه می‌شود:

$$\omega_{ij} = (1 + \log(tf_{ij})) \times \log(N/df_i) \quad (3)$$

جایی که  $\omega_{ij}$  وزن  $i$ -ام n-gram را در سند  $i$ -ام (بررسی) بیان می‌کند.  $j = 1, 2, \dots, N$ ؛  $df_i$  و  $tf_{ij}$  به ترتیب بیانگر فرکانس

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 صحیح‌تر 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 اسکپ گرام آموزش داده می‌شود.

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

برای آنالیز داده‌ها پیش‌پردازش بر روی اسناد آموزشی انجام شده و داده‌های گسیخته حذف شده، و بردارهای مبتنی بر  $tf-idf$  از متن ورودی به دست آمده و بردارهای حاصله، نرمال‌سازی می‌شوند. در مرحله پیش‌پردازش کاهش ابعاد بر روی متون انجام می‌گردد [۲۴]. در نهایت بعد از پیش‌پردازش که در زیر جزئیات آن شرح داده شده، داده‌های پیش‌پردازش شده به عنوان داده‌های آموزشی برای اعتقادکاووی و رده‌بندی نظرات روش پیشنهادی اعمال می‌گردد.

در تحلیل احساسات و دسته‌بندی خودکار نظرات از یادگیری عمیق مبتنی بر احساس-کلمه CNN\_WSD, LSTM\_WSD بر روی اسناد انجام می‌شود. CNN (Convolutional Neural Networks), LSTM (Long-Short-Term Memory) پنهان متراکم برای پردازش در ویژگی‌های ورودی استفاده می‌شود. این دو نمایندگی شامل احساس-کلمه و n-gram است.

بازنمایی کلمه-احساس در دو مرحله تولید می‌شود: در مرحله اول، تعبیه کلمات با استفاده از مدل اسکپ گرام آموزش داده می‌شود. 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 [۳].

برای محاسبه ماتریس وزن تعبیه شده، عملکرد تعبیه شده برای هر کلمه  $\omega_t$  در واژگان اعمال می‌شود. تابع تعبیه برای دنباله  $\omega = \{\omega_1, \omega_2, \dots, \omega_t, \dots, \omega_T\}$  کلمات آموزش داده شده تا عملکرد تابع هدف زیر به حداکثر برسد:

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

<sup>1</sup> Outlier

<sup>2</sup> Term Frequency-Inverse Document Frequency

## 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

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

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

while  $i < n$  do

if  $P(W_o|W_i)$

$vw$  is the vector marker of the input words and  $v'w$  represent the vector marker of the output words.

$x = \text{Softmax}(Wt + j) // \text{Equation (2)}$

If  $x$  is integer,  $[[x]] = 1$ ; Otherwise  $[[x]] = -1$ .

If  $x$  is correct,  $[[x]] = 1$ ; Otherwise  $[[x]] = -1$ .

end if where  $(W_{ij}$  weight of each  $n$ -gram in the document) // Equation(۳)

Repeating number or using the frequency product of each word

$tf\_idf // \text{Equation (4)}$

$i = i + 1$

Obtain well-trained sentiment- word embeddings(WSD): using synonym Word and the words of the context around it.

end while

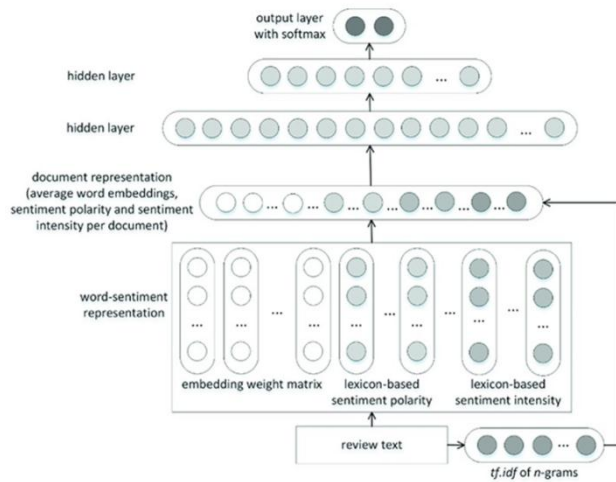
return.

مراحل طراحی روش پیشنهادی در ادامه بیان شده است.

## ۴-۱- پیش‌پردازش و خلاصه‌سازی 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 بی‌ارزش که متناوباً 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 می‌گردند.

اصطلاحات و اسناد<sup>۱</sup> هستند. بنابراین، طول بررسی در نظر گرفته می‌شود، و وزن نسبتاً بالاتری به  $n$ -gram نادر اختصاص می‌یابد. برای پردازش بیشتر،  $n$ -gramها با توجه به وزن آنها رتبه‌بندی می‌شوند، و  $n$ -gramهای برتر برای ورود به لایه بازنویسی اسناد در معماری CNN\_WSD, LSTM\_WSD انتخاب می‌شوند.



## 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 یکپارچه‌سازی ترک خوردگی ۰,۲ و ۰,۵ برای ورودی و دو لایه پنهان استفاده کردیم. الگوریتم نزول شیب مینی دسته‌ای با  $b = 100$  مینی دسته<sup>۲</sup>، میزان یادگیری ۰,۱ و ۱۰۰۰ تکرار، رفتار همگرایی خوب و پایدار را برای ما فراهم کرده است. اعداد مختلف  $nh_1$  و  $nh_2$  در دو لایه پنهان برای به دست آوردن معماری مطلوب مورد آزمایش قرار گرفت. همانطور که در زیر ارائه می‌شود، بهترین نتایج برای  $nh_1 = 25$  و  $nh_2 = 24$  نوروں بدست آمد. توجه داشته باشید که ما همچنین با یک لایه پنهان آزمایش کرده‌ایم اما بدون پیشرفت. عملکرد هدف با از دست دادن آنتروپی متقاطع نشان داده شد. پیچیدگی کلی مدل ارائه شده می‌تواند به صورت:

$$O(b \times I \times (m \times nh_1 + nh_1 \times nh_2 + nh_2 \times n_0))$$

بیان شود، که  $I$  تعداد تکرارها را نشان می‌دهد.  $m$  تعداد ویژگی‌های موجود در لایه ارائه اسناد را نشان می‌دهد.  $nh_1$  و  $nh_2$  به ترتیب تعداد نوروں‌ها در لایه‌های پنهان اول و دوم و لایه خروجی را نشان می‌دهند.

<sup>1</sup> Term and Document Frequency

<sup>2</sup> Mini-batches



## الگوریتم ۲. نحوه تخصیص شدت احساس کلمات

کمتر به وجود می‌آیند که بعد از انجام اعمالی نظیر رده‌بندی، جواب‌هایی مشابه داده‌های اولیه تولید می‌کنند، در روش پیشنهادی برای حل این مسئله از پارامترهای معکوس فرکانس (tf-idf) و مطابقت کلمات در کلاس (uni) و یکنواختی (ICF) مربوط به هر کلمه استفاده می‌کند، سپس کلمه ای را انتخاب می‌کند که حد آستانه کوچکتر از ICF و uni مشخص و بزرگتر از حد آستانه تعیین شده داشته باشد.

در حقیقت این پارامترها سعی می‌کنند با امتیاز دادن به تکرار کلمه در کلاس‌های کمتر و تعداد رخداد بیشتر آن در یک کلاس، کلماتی را به عنوان ویژگی نهایی انتخاب کنند که نماینده یک کلاس خاص باشند.

## ۴-۱-۲- بازنمایی متون با روش تعبیه واژه‌های عصبی

برای وزندهی به ویژگی‌ها می‌توان از رویکردهای متفاوتی بهره برد. در ساده‌ترین حالت این وزندهی می‌تواند به صورت باینری 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:

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

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

در نظر کاوی داده‌ها با یادگیری عمیق ابتدا داده‌های متنی باید با روش‌های رمزنگاری 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 تعبیه واژه‌های عصبی در مدل‌های یادگیری عمیق بهره مند می‌شویم که هر کلمه به یک بردار کم ابعاد به نام ویژگی کلمه تبدیل می‌شود [۲۶]. 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 بگیرند، شباهت بیشتری خواهند داشت. شایان ذکر است که تعبیه کلمه عصبی نه تنها یک ردیاب 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 متکی است و در فرایند یادگیری عصبی عملی خواهد شد. در

```
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:
6: Score = 0
7: Word = Lemmatization(W) // Lemmatize the word
8: Synsets = GetSynsets_SentiWordNet(Word) // Obtain the synsets 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 if Score <= -1
19: append (W: "Negative") to Sentiment_class if -1 < Score < 0
20: append (W: "Neutral") to Sentiment_class if Score == 0
21: append (W: "Positive") to Sentiment_class if 0 < Score < 1
22: append (W: "Strong Positive") to Sentiment_class if Score >= 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 SentiWordNet و Sentpres 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،  $Synsetp$  نشان دهنده امتیاز مثبت و  $Synsetn$  نشان دهنده امتیاز منفی است.

## ۴-۱-۱- انتخاب ویژگی اولیه

انتخاب ویژگی، تکنیکی است که برای مواجهه با داده‌های با ابعاد بالا<sup>۱</sup> 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

<sup>1</sup> High dimensional

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

قطبیت هر جمله از یک مجموعه E بین بازه +۲ و -۲ انتخاب شده،  $E = \{-2, -1, 0, +1, +2\}$  که در جدول ۱ نمایش داده شده است.

#### ۴-۳- پردازش داده

عملکرد یادگیری ماشین و یادگیری عمیق اغلب به اندازه و کیفیت داده‌های آموزشی بستگی دارد که جمع آوری آنها اغلب خسته‌کننده است [۲۷]، بنابراین، از چندین مجموعه داده متعادل استفاده شده است.

در این مقاله از مجموعه داده توئیتر فارسی استفاده شده، نظرات فارسی در مجموعه داده شبکه اجتماعی توئیتر شامل ۱۰۰۰۰۰۰ سند است، برای هر دسته نظرکاوی با مثبت و منفی بودن نظر کاربران نمایش داده می‌شود.

#### ۵- نتایج و آزمایشات

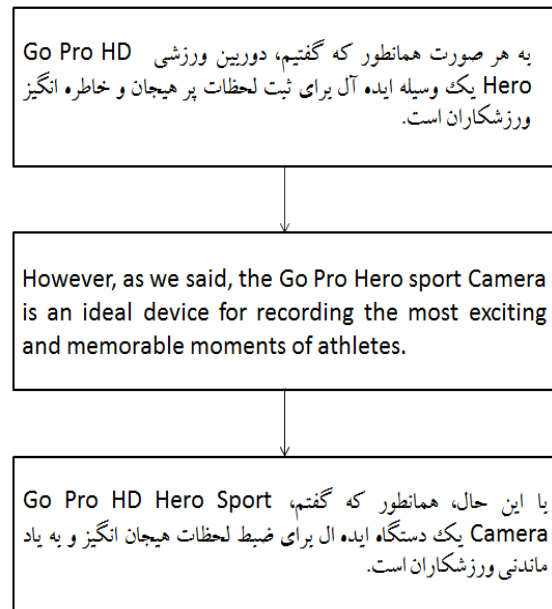
در اعتقادیابی هر کلمه به عنوان یک ویژگی در داده‌های آموزشی برای رده‌بندی در نظر گرفته می‌شود و کلمات در متون فارسی بر اساس نرخ تاثیر در نظرکاوی در رده‌بندی اندازه‌گیری می‌شود و بر اساس میزان دقت Acc و زمان رده‌بندی اندازه‌گیری می‌شود.

این آزمایشات بر روی مجموعه داده توئیتر با ۱۰۰۰۰۰۰ سند انجام شده است. ما از مدل‌های یادگیری عمیق مبتنی بر شدت احساسات کلمات با TF-IDF و تعبیه کلمات بر روی مجموعه داده‌های توئیتر استفاده کرده‌ایم. برای یادگیری تعبیه کلمات (word embeddings)، از مدل Skip-Gram برای آموزش داده‌ها استفاده شده است [۲۸-۳۲].

#### ۵-۱- مجموعه داده توئیتر

نظرات فارسی در مجموعه داده شبکه اجتماعی توئیتر شامل ۱۰۰۰۰۰۰ سند است، برای هر دسته نظرکاوی با مثبت و منفی بودن نظر کاربران نمایش داده می‌شود.

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 تعبیه بردارها را نشان می‌دهد. شکل ۳ نحوه آنلاین بودن را نشان می‌دهد.



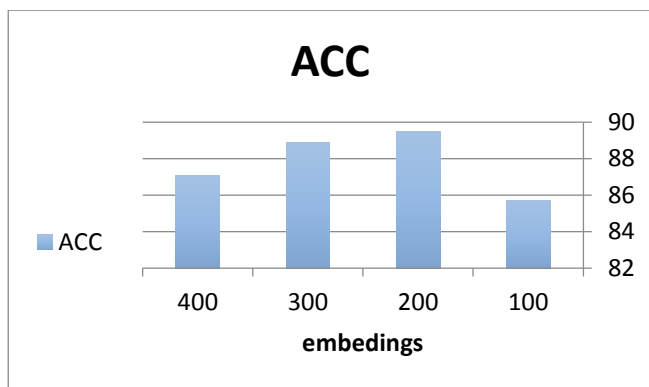
شکل ۳. لایه جاسازی آنلاین

#### ۴-۲- اعتقادکاوی

در اعتقادکاوی، هم بازخوردهای مثبت و هم منفی مجموعه داده استفاده شده که نظرات فارسی کاربران در توئیتر می‌باشد را با استفاده از روش پیشنهادی CNN\_WSD, LSTM\_WSD رده‌بندی و درصد بازخورد مثبت و منفی نظرات کاربران در مورد هر یک از موضوعات استخراج می‌شود 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، زشت، نامناسب، افتضاح و غیره) مربوط به هر موضوع محاسبه می‌شود. در مجموعه داده آموزشی هر جمله با ویژگی‌هایی مانند قطب، کلمات کلیدی و اهداف شرح داده می‌شود.

جدول ۱. مجموعه‌ای از احساسات رتبه‌بندی شده بر اساس قطبیت

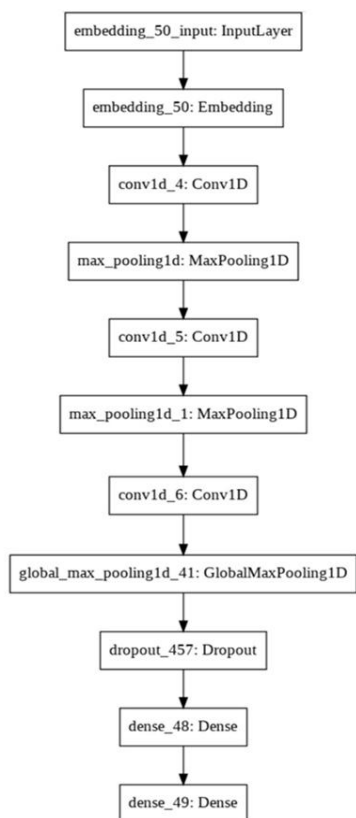
جدول ۲. رتبه‌بندی جملات مجموعه داده توئیتر



شکل ۵. تأثیر تعداد تعبیه کلمات بر عملکرد مدل CNN\_WSD, LSTM\_WSD با دو لایه پنهان از  $nh1 = 25$  و  $nh2 = 24$  نرون.

### ۵-۳- مدل‌ها

در این قسمت از ساختار LSTM مبتنی بر تعبیه کلمات برای لایه‌های شبکه عصبی استفاده شده است. نخستین ساختار حافظه طولانی کوتاه مدت دوطرفه (LSTM) است که بر پایه شبکه‌های 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 لایه‌های تعبیه شده برای این ساختار قابل مشاهده است.



شکل ۶. ساختار لایه‌های در مدل‌های پیشنهادی LSTM-WSD

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

مجموعه داده تویتر 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.

R	J	I	H	G	F	E	D	C	B	A	1
tweet	place	name	username	user_id	timezone	time	date	created_at	conversat	id	
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱

شکل ۴. نمونه مجموعه داده تویتر

ما از فیلدهای target, text برای انجام آزمایشات استفاده می‌کنیم. تعداد جمله‌های تمام دسته‌ها ۱۰۰۰۰۰۰ می‌باشد که تعداد داده‌های هر دسته نیز در جدول ۲ مشخص شده است [۳].

### ۵-۲- پارامترها

از آنجا که هر متن به صورت مجموعه‌ای از کلمات تعبیه شده در آمده، در لایه اول مدل‌های شبکه عصبی خود، تعداد نرون‌ها به اندازه بیشترین طول جملات بر حسب کلمه است. در این مجموعه داده، طولانی‌ترین 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 کرده‌ایم. در تعبیه کلمات به کمک Keras، در مدل‌های 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  $num\_words = 2000$  در نظر گرفته شده است. مدل اسکپ گرام در محیط پایتون پایتون با استفاده از سیستم یادگیری عمیق کلب گوگل<sup>۱</sup> آموزش داده شد.

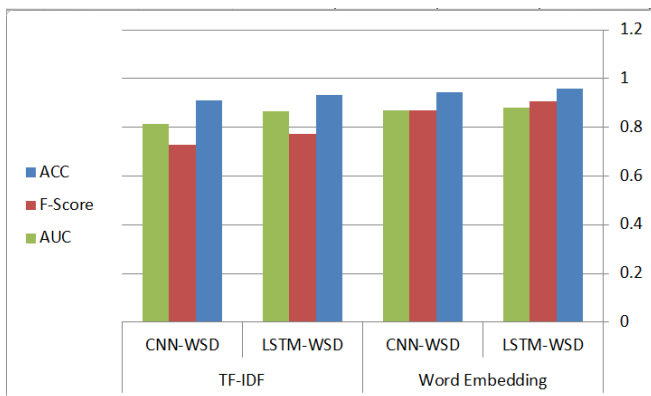
<sup>۱</sup> Colab google

نتایج شکل ۸ نشان می‌دهد، بهترین رفتار با ترکیب LSTM و تعبیه کلمات (Word embedding) نشان داده می‌شود و بالاترین مقادیر ACC، F\_Score و AUC با تعبیه کلمات LSTM + داده شد. ما می‌توانیم تأیید کنیم که تعبیه کلمات یک تکنیک مناسب‌تر از TF-IDF برای انجام تجزیه و تحلیل احساسات است، پس از تجزیه و تحلیل نتایج مربوط به کیفیت پیش‌بینی‌ها، لازم است اطلاعاتی در مورد هزینه محاسباتی مرتبط با القاء مدل‌ها به دست آوریم.

جدول ۴ زمان پردازش مورد نیاز برای القاء مدل‌ها از مجموعه داده تویتر را نشان می‌دهد و شامل زمان CPU مورد نیاز در آزمایش‌ها است. این جدول نشان می‌دهد که استفاده از TF-IDF، به زمان محاسبه طولانی‌تری نسبت به استفاده از تعبیه کلمات (Word Embedding) نیاز دارد. این یکی دیگر از دلایلی است که تکنیک تعبیه کلمات را توصیه می‌کنیم. با این حال، LSTM با TF-IDF و هم با تعبیه کلمات وقت‌گیرترین الگوریتم است.

در نهایت، خلاصه کلی از نتایج بدست آمده در آزمایشات را در زیر توضیح می‌دهیم:

دو مدل یادگیری عمیق (CNN و LSTM) با تفکیک شدت احساس کلمات برای انجام آزمایش‌های تجزیه و تحلیل احساسات استفاده شد. مشخص شد که مدل LSTM بهترین نتیجه بین زمان پردازش و دقت نتایج را ارائه می‌دهد.



شکل ۸. نمودار ارزیابی روش‌های یادگیری عمیق در مجموعه داده تویتر

جدول ۴. زمان آزمایشات مدل‌های مختلف روش پیشنهادی با پردازنده گرافیکی GPU

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

در این قسمت ساختار CNN مبتنی بر تعبیه کلمات (WSD برای لایه‌های شبکه عصبی استفاده شده است، در روش پیشنهادی شبکه عصبی کانولوشن (CNN) است که یکی از موفق‌ترین ساختارهای شبکه‌های عصبی است این مدل برای داده‌های متنی خصوصاً در مسائل طبقه‌بندی 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 لایه‌های در مدل‌های پیشنهادی CNN

## ۵-۴- نتایج

در آزمایشات ما، سه روش ارزیابی بر روی مجموعه داده تویتر در نظر گرفته می‌شود: 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 می‌باشد.

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 F-Score برابر با ۰.۸۷۱ و AUC برابر با ۰.۸۸۹ است.

نتایج جدول ۳ نشان می‌دهد استفاده از تعبیه کلمات برای تحلیل احساسات با یادگیری عمیق نتایج بهتری نسبت به TF-IDF برای ارزیابی دقت (Acc)، مساحت زیر منحنی (AUC) و F-Score دارد.

جدول ۳. نتایج آزمایش‌های ACC، F-Score و AUC برای تویتر

مجموعه داده‌ها

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

LSTM نسبت به DNN و CNN در مورد اخیر چندان قابل توجه نیست، استفاده از این دو روش را می‌توان از نظر کاهش زمان و هزینه محاسباتی مناسب‌تر دانست، البته انواع مختلف مجموعه داده‌ها بر نتایج تجزیه و تحلیل احساسات متفاوت تأثیر می‌گذارد.

جدول ۵. مقایسه و ارزیابی نتایج روش پیشنهادی با سایر مدل‌های 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 [3]	84.05 ± 0.28	0.917 ± 0.003	0.841 ± 0.002	2.042 ± 0.128
CNN [33]	84.29 ± 0.17	0.921 ± 0.001	0.844 ± 0.003	8.139 ± 0.286
DNN [34]	84.14 ± 0.71	0.842 ± 0.002	0.828 ± 0.005	8.14 ± 0.31
Tree-LSTM & Discourse-LSTM [35]	86.06 ± 0.28	0.867 ± 0.006	0.851 ± 0.003	4.15 ± 0.11
GRU, and hybrid approaches [9]	85.29 ± 0.16	0.851 ± 0.002	0.854 ± 0.006	11.2 ± 0.31
RNN [36]	84.74 ± 0.91	0.850 ± 0.003	0.838 ± 0.008	9.16 ± 0.21
Coattention-LSTM + Location [37]	87.52 ± 0.19	0.891 ± 0.002	0.871 ± 0.003	5.032 ± 0.18
Bi-LSTM [38]	84.85 ± 0.06	0.871 ± 0.002	0.841 ± 0.003	3.042 ± 0.45

جدول ۶. نتایج آزمایش‌های ACC، F-Score و AUC برای توییت‌ر مجموعه داده‌ها.

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

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 تکنیک TF-IDF موثر نیست و زمان پردازش بسیار بیشتر آن منجر به نتایجی می‌شود که بهتر نیستند. برای ارزیابی جامع اثربخشی مدل پیشنهادی، عملکرد آن را در مقابل مدل‌های موجود زیر مقایسه کردیم. در جدول ۵ روش‌های مختلف یادگیری عمیق از جمله LSTM، CNN، DNN، Tree-LSTM، RNN، GRU، Bi-LSTM و Coattention-LSTM که از سال‌ها ۲۰۱۸ تا ۲۰۲۳ توسط محققین برای تحلیل احساسات بر روی مجموعه داده توییت‌ر استفاده شده است، با استفاده از نرم‌افزار پایتون برای مجموعه داده فارسی توییت‌ر پیاده‌سازی و شبیه‌سازی شده‌اند و در حالت برابر ارزیابی شده است، با توجه به اینکه روش‌های یادگیری عمیق عملکرد بهتری نسبت به روش‌های یادگیری ماشین دارد ما فقط روش‌های پرکاربرد یادگیری عمیق را مورد ارزیابی و مقایسه قرار داده‌ایم.

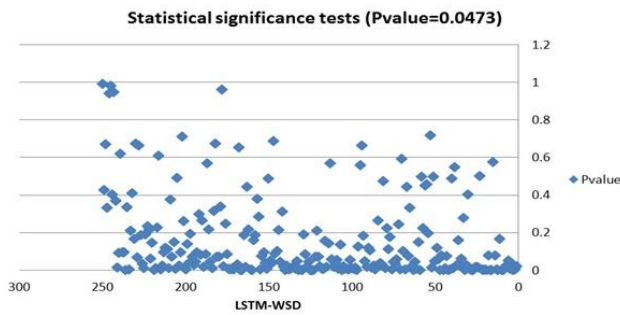
نتایج جدول ۵ نشان می‌دهد، بهترین رفتار با ترکیب LSTM-WSD و تعبیه کلمات نشان داده می‌شود و بالاترین مقادیر ACC، F\_Score و AUC با تعبیه کلمات LSTM + داده شد. همچنین روش CNN-WSD با تعبیه کلمات نیز نسبت به اکثر روش‌های مورد مقایسه نتایج بهتری داشته و زمان اجرای مدل CNN نسبت به LSTM بهتر می‌باشد، نتایج بدست آمده نشان می‌دهد روش‌های LSTM، Tree LSTM و Bi LSTM زمان اجرای پایین‌تری نسبت به مدل‌های تعبیه کلمات و TF-IDF برای انجام تجزیه و تحلیل احساسات است، اما میزان دقت طبقه‌بندی این سه مدل به ترتیب ۰.۹۱٪، ۰.۸۶٪ و ۰.۸۴٪ درصد است. پس از تجزیه و تحلیل نتایج مربوط به کیفیت پیش‌بینی روش‌های مورد ارزیابی ما در جدول ۶ نتایج روش LSTM-WSD را برای مدل‌های تعبیه کلمات و TF-IDF را با روش DNN-WSD (حساس به کلمه) مقایسه می‌کنیم.

نتایج جدول ۶ نشان می‌دهد در رفتار هر دو مدل تعبیه کلمات و TF-IDF مدل مورد ارزیابی DNN-WSD برای تحلیل احساسات بر روی مجموعه داده توییت‌ر عملکرد مناسبی ندارد و مدل‌های LSTM و CNN عملکرد بهتری نسبت به DNN عملکرد بهتری دارند. جداول ۴ و ۶ نشان می‌دهد که استفاده از TF-IDF، به زمان محاسبه طولانی‌تری نسبت به استفاده از تعبیه کلمات نیاز دارد. این یکی دیگر از دلایلی است که تکنیک تعبیه کلمات را توصیه می‌کنیم. با این حال، LSTM وقت‌گیرترین الگوریتم است، هم با TF-IDF و هم با Word Embedding. با توجه به اینکه بهبود

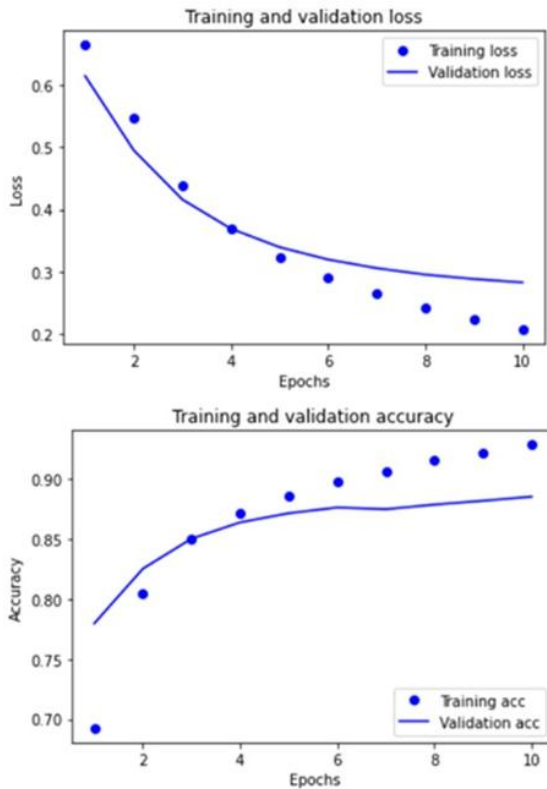
آزمون‌های معنی‌داری آماری که ما انجام دادیم راهی برای ارزیابی نتایج آزمون‌ها در اختیار ما قرار داد. سطح قابل اعتمادی که معمولاً برای نتایج استفاده می‌شود ۹۵٪ است، همچنین به صورت  $p = 0.05$  نوشته می‌شود و به عنوان سطح  $p$  شناخته می‌شود. همانطور که در شکل ۱۱ نشان داده شده است، آزمون‌های معناداری آماری را برای آموزش و اعتبار سنجی اضافه کردیم.

شکل ۱۲ عملکرد مدل پیشنهادی LSTM+WSD را بر اساس ۱۰ دوره نشان می‌دهد.

حداکثر میزان دقت برای ۱۰ تکرار ۹۳٪ و میزان خطا ۰٫۱۸۹ برای LSTM آموزش مدل تعبیه کلمه است، اما در Validation میزان دقت ۸۸٪ و میزان خطا برای ۱۰ تکرار ۰٫۲۸۱ است.



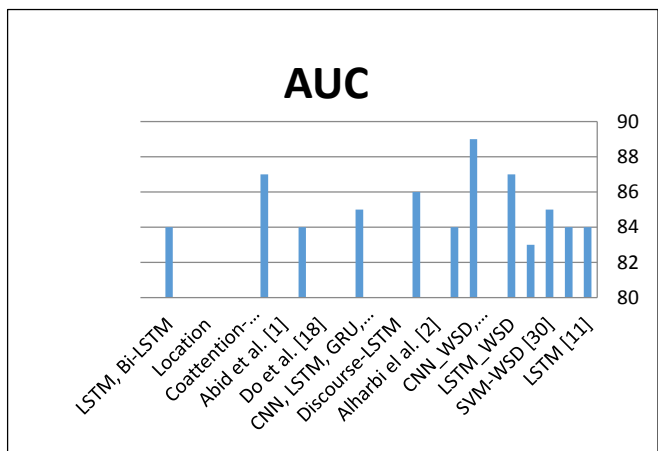
شکل ۱۱. نمودار Pvalue برای آزمون‌های معناداری آماری.



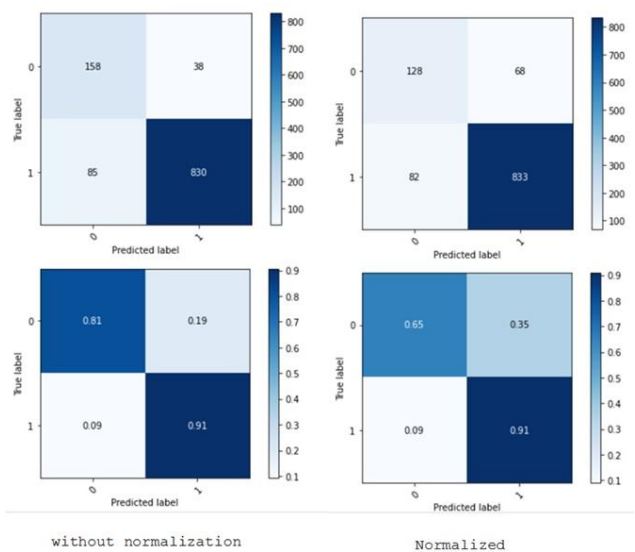
شکل ۱۲. نمودار دقت بر اساس دوره‌ها.

نتایج شکل ۹ نشان می‌دهد که میزان مساحت زیر منحنی AUC روش LSTM\_WSD برابر با ۸۶٫۴۹، CNN\_WSD برابر با ۸۸٫۹۲ است.

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 نرمال‌سازی 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 می‌شود (شکل ۱۰).



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



شکل ۱۰. نمودار سردرگمی برای LSTM+WSD

## ۵-۵- بحث

با توجه به جداول ۳ تا ۶ می‌توان نتیجه گرفت که Recall، دقت، AUC و F-score روش پیشنهادی LSTM و تعبیه کلمه بهتر از سایر روش‌های ارزیابی شده است.

این نتایج برای ترکیب LSTM و TF-IDF به ترتیب ۰,۷۷۶، ۰,۷۷۴، ۰,۶۴۱ و ۰,۵۶۹ است. نتایج به‌دست‌آمده در مقایسه با تعبیه کلمات و TF-IDF برای مجموعه داده توپیتر و سایر مجموعه‌های داده مبتنی بر روش LSTM نشان می‌دهد که نتایج تعبیه کلمات در LSTM بهتر از TF-IDF است.

همچنین برای ترکیب CNN + جاسازی کلمه و DNN + جاسازی کلمه، Recall ۰,۸۰۲ و ۰,۷۹۱، میزان دقت ۰,۸۰۲، ۰,۷۹۱، FScore 0.788، 0.801 است.

نتایج به‌دست‌آمده نشان می‌دهد که روش تعبیه کلمه و LSTM با دقت ۹۳ درصد و درصد خطای ۰,۱۸۹ نسبت به سایر روش‌های ارزیابی شده عملکرد بهتری دارند. اما زمان اجرای LSTM و تعبیه کلمه بیشتر از CNN و DNN است.

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

دوم: نتایج نشان می‌دهد که باور کاوی شامل رشته‌های بسیاری مانند علوم کامپیوتر، زبان‌شناسی و مهندسی برق است که نشان‌دهنده روند تحقیقات بین‌رشته‌ای است.

بنابراین، کارهای آینده باید از اسناد متنوع برای کشف ماهیت بین رشته‌ای استفاده کنند.

## ۵-۶- پیشنهادات و کاربردها

با توجه به اینکه حجم داده در شبکه‌های اجتماعی و وبسایت‌ها بالا است و بر اساس قطبیت کلمات تحلیل احساسات و اعتقادکاوی بر روی جملات انجام می‌شود پیشنهاد می‌شود از روش‌های یادگیری عمیق برای افزایش دقت طبقه‌بندی در تحلیل احساسات و اعتقادکاوی استفاده شود.

نتایج بدست آمده از این پژوهش نشان می‌دهد که عملکرد مدل یادگیری LSTM حساس به کلمه (WSD) نسبت به سایر مدل‌های یادگیری عمیق DNN، RNN و CNN بهتر است. همچنین مدل تعبیه کلمات عملکرد بهتری نسبت به TF-IDF

برای تجزیه و تحلیل نظرات دارد.

به محققان پیشنهاد می‌شود بر روی مدل‌های یادگیری عمیق LSTM و کانولوشن + تعبیه کلمات و مدل‌های ترکیبی بر اساس حساسیت به کلمات و دیدگاه کاربران فعالیت کنند.

تحلیل احساسات و اعتقادکاوی داده‌های شبکه‌های اجتماعی باعث درک نظرات کاربران شده و کاربردهای گسترده‌ای در تصمیم‌گیری و سیاست‌گذاری‌ها دارد و در زمینه‌های مختلف سیاسی، اجتماعی، اقتصادی، فرهنگی و ورزشی کاربرد دارد.

به عنوان مثال در زمینه اقتصادی تحلیل نظرات کاربران بر روی محصولات می‌تواند به فروشگاه‌ها و تولید کنندگان کمک کند تا نظرات مشتریان را تحلیل کند تا سیاست‌گذاری و تصمیم‌های مناسب را جهت افزایش جذب مشتریان انجام دهند.

در زمینه سیاسی به دولت‌ها کمک می‌کند در زمینه‌های مختلف نظرات کاربران را در شبکه‌های اجتماعی تحلیل کنند و سیاست‌گذاری‌های خود را بر اساس دیدگاه و نظرات مردم انجام دهد.

در تحقیقات آینده، با بررسی انجمن‌های احساسات-کلمه (word-sentiment) و همچنین دیدگاه‌های کاربران در حوزه‌های مختلف می‌توان تجزیه و تحلیل کامل‌تری انجام داد. یکی از محدودیت‌های مدل پیشنهادی این است که در آن فقط ویژگی‌های محلی ضبط شده‌اند. استخراج ویژگی n-gram استفاده شده در این تحقیق، شباهت معنایی یا توانایی تمایز کلمات را در نظر نمی‌گیرد. بنابراین، نمایش‌های n-gram افزایش یافته [۳۹] برای کاهش ابعاد و کمی بودن داده‌ها توصیه می‌شود. استفاده از یک روش انتخاب ویژگی مؤثر نیز ممکن است منجر به کاهش پیچیدگی محاسباتی و بهبود راندمان زمانی شود [۴۰] از طرح‌های جایگزین مبتنی بر تعبیه نیز می‌توان استفاده کرد [۴۱-۴۸].

## ۶- نتیجه‌گیری

در این مطالعه، ما مدل پیشنهادی LSTM، CNN، کارآمد با تفکیک شدت احساسات بر روی کلمه WSD برای استخراج نظر و اعتقادکاوی ارائه داده‌ایم. ما با انجام آزمایشات گسترده در مجموعه داده فارسی توپیتر [۴۲]، عملکرد مدل را در مقایسه با نمایش‌های اولیه کلمه ثابت کردیم. ما مدل پیشنهادی را با روش‌های موجود یادگیری عمیق و سایر روش‌های یادگیری ماشین مقایسه کردیم [۴۹-۵۵]. از این رو، اثربخشی مدل ارائه شده نشان داده شد.

- [12] 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.
- [13] *Dashtipour, K., Gogate, M., Adeel, A., Ieracitano, C., Larijani, H., & Hussain, A. (2018). Exploiting deep learning for Persian sentiment analysis. In Advances in Brain Inspired Cognitive Systems: 9th International Conference, BICS 2018, Xi'an, China, July 7-8, 2018, Proceedings 9 (pp. 597-604). Springer International Publishing.*
- [14] Basiri, M.E. and kabiri, A., (2018), Words Are Important: Improving Sentiment Analysis in the Persian Language by Lexicon Refining, *ACM Transactions on Asian and Low-Resource Language Information Processing (TALLIP)*, Vol 17(4), pp. 1145-1154.
- [15] S. Urologin, 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, 2018.
- [16] 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.
- [17] 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, technology & applied science, New Zealand-Auckland, 2019.
- [18] 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.
- [19] 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.
- [20] 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.
- [21] K. Wang and X. Wan, Counterfactual Representation Augmentation for Cross-Domain Sentiment Analysis. *IEEE Transactions on Affective Computing*, 2022.
- [22] 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*.
- [23] 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.
- [24] 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.
- [25] 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, 2020. [https://doi.org/10.1007/978-3-030-49161-1\\_35](https://doi.org/10.1007/978-3-030-49161-1_35).
- [26] 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.
- نتایج آزمایشات نشان می‌دهد که تفکیک شدت احساسات کلمات فقط بر اساس تعبیه کلمات مؤثر هستند. ادغام WSD با N-gram، پیشرفت بیشتری را ارائه می‌دهد.
- در این پژوهش، علاوه بر تحلیل احساسات بر روی مجموعه داده، احساسات کاربران در مقوله‌های مختلف سیاسی، اقتصادی، فرهنگی و علمی مورد تجزیه و تحلیل قرار گرفت تا تحلیل‌گران بتوانند جهت‌گیری فکری کاربران در آن زمینه و دیدگاه‌های 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 روش‌های یادگیری عمیق موجود و سایر روش‌های یادگیری ماشین برای نشان دادن اثربخشی مقایسه شد.

## مراجع

- [1] Liu, B., 2012. Sentiment Analysis and Opinion Mining. *Synthesis lectures on human language technologies*, pp. 1-167.
- [2] 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.
- [3] *Alikarami, H., Bidgoli, A. M., & Javadi, H. H. S. (2023). Belief Mining in Persian Texts Based on Deep Learning and Users' Opinions. IEEE Transactions on Affective Computing*, 15(2), 632-643.
- [4] *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.*
- [5] 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.
- [6] 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.
- [7] 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)
- [8] D. Tang, B. Qin, T. Liu.: 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). 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.
- [9] 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.
- [10] *Shams, M., Shakery, A., & Faili, H. (2012, May). A non-parametric LDA-based induction method for sentiment analysis. In The 16th CSI international symposium on artificial intelligence and signal processing (AISP 2012) (pp. 216-221). IEEE.*
- [11] *Basiri, M. E., Naghsh-Nilchi, A. R., & Ghassem-Aghaee, N. (2014). A framework for sentiment analysis in persian. Open transactions on information processing*, 1(3), 1-14.



- [42] Hosseini, P. et al., 2018. SentiPers: A Sentiment Analysis Corpus for Persian.
- [43] Catal, C., Nangir, M.: A sentiment classification model based on multiple classifiers. *Appl. Soft Comput.* 50, 135–141 (2017)
- [44] 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.
- [45] 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.
- [46] Chen, Z.; Liu, B. Lifelong machine learning. *Synth. Lect. Artif. Intell. Mach. Learn.* 2018, 12, 1–207. [CrossRef]
- [47] Kim, Y., 2014. Convolutional Neural Networks for Sentence Classification. Doha, Qatar, s.n.
- [48] LeCun, Y., Bengio, Y. & Hinton, G., 2015. Deep learning. *Nature*, Volume 521, pp. 436-444.
- [49] 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.
- [50] 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, technology & applied science, New Zealand-Auckland, 2019.
- [51] 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.
- [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
- [54] Roustaei, A. and Rastegari, H., (2018), Persian question classification using headword and semantic features, *IEEE, Journal of Theoretical and Applied Information Technology*, Vol 96(21), pp. 7206-7214.
- [55] Kausar, S., Huahu, X., Shabir, M.Y., Ahmad, W.: A sentiment polarity categorization technique for online product reviews. *IEEE Access* 8, 3594–3605 (2019)
- [27] 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.
- [28] Available online: <http://alt.qcri.org/semeval2017/> (accessed on 12 March 2020).
- [29] Available online: <http://help.sentiment140.com/site-functionality> (accessed on 12 March 2020).
- [30] Available online: <http://www.cs.cornell.edu/people/pabo/movie-review-data/> (accessed on 12 March 2020).
- [31] Available online: <https://www.kaggle.com/c/word2vec-nlp-tutorial/data> (accessed on 12 March 2020).
- [32] Available online: <https://www.kaggle.com/crowdflower/twitter-airline-sentiment> (accessed on 12 March 2020).
- [33] 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.
- [34] 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.
- [35] 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.
- [36] Hassan, A. and Mahmood, A., (2018), Convolutional Recurrent Deep Learning Model for Sentence Classification, *IEEE*, Vol 6, pp. 13949 – 13957.
- [37] C. Yang, H. Zhang, B. Jiang and K.J. Li, Aspect-based sentiment analysis with alternating coattention networks. *Inf. Process. Manag.* 2019, 56, 463–478.
- [38] C. Wu, F. Wu, S. Wu, Z. Yuan, J. Liu and Y. Huang, Semi-supervised dimensional sentiment analysis with variational autoencoder. *Knowl. Based Syst.* 2019, 165, 30–39.
- [39] 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)
- [40] 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)
- [41] 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.