Semnan University

Journal of Modeling in Engineering

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

ISSN: 2783-2538

Research Article

Aspect-based sentiment analysis based on users' comments in an online marketplace

Fatemeh Moodi[1], Amir Jahangard-Rafsanjani [2,*], Fatemeh Sadri[3]

[1,2,3] *Department of Computer Engineering, Yazd University, Yazd, Iran*

PAPER INFO

Paper history:

Received:
Revised:
Accepted:

Keywords:

Sentiment analysis;
FastText;
Different aspects of comments;
Deep learning;
Convolutional neural network;
BERT.

ABSTRACT

In recent years, with the expansion of online shopping and the importance of user feedback in improving the quality of products and services, sentiment analysis of user reviews has become one of the most important tools and opportunities for online businesses and services. In this research, various approaches based on Convolutional Neural Networks (CNN), BERT language model, and FastText language model have been examined for sentiment analysis of user reviews about mobile phones in aspects such as camera, battery, and price in an online marketplace. In this regard, the data were labeled based on aspects and categorized into three sentiments: positive, negative, and neutral. Additionally, to improve the performance of the proposed approaches and address data imbalance, data augmentation methods were utilized and their impact was analyzed. Finally, using the proposed models, very high accuracy in detecting positive, negative, and neutral reviews in each aspect was achieved. According to the results, the proposed CNN-based approach performed better than the other two proposed methods on the given data.
DOI: https://doi.org/

*** Corresponding author.**
E-mail address: jahangard@yazd.ac.ir

How to cite this article:

مقاله پژوهشی

تحلیل احساسات مبتنی‌بر جنبه روی نظرهای کاربران در یک بازارگاه برخط

فاطمه مودی[۱]، امیر جهانگرد-رفسنجانی[۲،*] و فاطمه صدری[۳]

اطلاعات مقاله

دریافت مقاله:

بازنگری مقاله:

پذیرش مقاله:

واژگان کلیدی:

تحلیل احساسات،

فست‌تکست،

جنبه‌های مختلف نظرها،

یادگیری عمیق،

شبکه عصبی پیچشی،

برت.

چکیده

در سال‌های اخیر، با توجه به گسترش خریدهای اینترنتی و اهمیت بازخورد کاربران در بهبود کیفیت محصولات و خدمات، تحلیل احساسات روی نظرهای کاربران به یکی از مهم‌ترین ابزارها و فرصت‌های پیش‌روی کسب‌وکارها و خدمات برخط تبدیل شده است. در این پژوهش رویکردهای مختلف مبتنی‌بر شبکه عصبی پیچشی، مدل زبانی برت و همچنین مدل زبانی فست‌تکست برای تحلیل احساسات نظرهای کاربران در مورد تلفن همراه در جنبه‌های دوربین، باتری و قیمت در یک بازارگاه اینترنتی بررسی شده است. در همین راستا، داده‌ها مبتنی‌بر جنبه و بر اساس سه احساس مثبت، منفی و خنثی برچسب‌گذاری شد. همچنین برای بهبود عملکرد رویکردهای پیشنهادی و عدم توازن بین داده‌ها، از روش‌های افزایش داده‌ها استفاده و تأثیر آن‌ها بررسی شده است. در نهایت با استفاده از مدل‌های پیشنهادی، دقت بسیار بالایی در تشخیص نظرهای مثبت، منفی و خنثی در هر جنبه به‌دست آمد. بر اساس نتایج، رویکرد پیشنهادی مبتنی‌بر شبکه عصبی پیچشی، عملکرد بهتری نسبت به دو روش پیشنهادی دیگر روی داده‌های مورد نظر داشته است.

DOI: https://doi.org/

۱-مقدمه

با گسترش استفاده از فضای وب، خریدهای اینترنتی و تعاملات برخط کاربران در سال‌های اخیر، بازخورد و نظرهای کاربران به‌عنوان منبعی ارزشمند از محتوای مصرفی در دنیای وب معرفی می‌شود. این عوامل، به سازمان‌ها امکان می‌دهد تا با تجزیه و تحلیل دقیق‌تر این ورودی‌ها و نظرهای کاربران، خدمات و محصولات خود را بهبود بخشند. همچنین، از این اطلاعات برای بهبود تجربه کاربری، بهبود عملکرد کلی سازمان و بهره‌برداری بهتر از منابع خود استفاده کنند [۱]. برای دستیابی به این اهداف، سازمان‌ها از تحلیل احساسات بهره می‌برند. این فرآیند شامل ارزیابی و تجزیه و تحلیل نظرهای کاربران برای شناخت و فهم بهتر احساسات، نگرانی‌ها و تمایلات آن‌ها است. با بهره‌گیری از این ابزارهای تحلیلی، سازمان‌ها می‌توانند به شناخت عمیق‌تری از واکنش‌ها و نیازهای مشتریان خود دست پیدا کنند و در نتیجه تصمیم‌گیری‌های بهتری داشته باشند.

امروزه، با پیشرفت تکنولوژی و افزایش خدمات برخط، تحلیل احساسات نظرهای مشتریان در یک بازارگاه برخط

* پست الکترونیک نویسنده مسئول: jahangard@yazd.ac.ir

۱. دانشکده مهندسی برق و کامپیوتر، گروه مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران.

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

اهمیت بسیار زیادی دارد و می‌تواند به پیشرفت آن کسب-وکار و افزایش رضایت مشتریان کمک کند. از جمله دلایل اهمیت تحلیل احساسات در کسب‌وکارها؛ درک نیازهای مشتری، کیفیت محصولات و خدمات، افزایش رضایت مشتریان، جذب مشتریان جدید و پیش‌بینی مشکلات آینده است.

کلمات، ابزاری برای بیان افکار، نظرهای و نیازهای افراد هستند. درعین‌حال، یک کلمه ممکن است در همه موارد معنی یکسانی نداشته باشد و معنی آن وابسته به کاربرد آن شکل می‌گیرد. این پیچیدگی در زبان‌ها از مواردی است که تحلیل احساسات را با چالش مواجه می‌کند. تحلیل احساسات در زبان فارسی، با وجود پیشرفت‌های قابل‌توجه در سال‌های اخیر، همچنان با چالش‌هایی روبه‌رو است [۲]. از مهم‌ترین این چالش‌ها می‌توان به موارد زیر اشاره کرد:

(۱) کمبود داده و منابع: در مقایسه با زبان‌هایی مانند انگلیسی، داده‌های کمتری برای تحلیل احساسات فارسی در دسترس است. این کمبود می‌تواند فرایند آموزش و تنظیم مدل‌ها را محدود کند [۳].

(۲) پیچیدگی ساختاری زبان فارسی: زبان فارسی دارای ساختار زبانی پیچیده‌ای است که شامل ترکیب‌های خاص کلمات و اصطلاحات متنوع می‌شود. همچنین، وجود اشتباه‌های املایی و نویزهای نوشتاری، دقت مدل‌های تحلیل احساسات را کاهش می‌دهد.

(۳) چندمعنایی واژگان: بسیاری از واژگان فارسی بسته به زمینه، معانی متفاوتی دارند. درک صحیح این واژه‌ها نیازمند تحلیل دقیق متن و شناخت درست کاربرد آن‌هاست [۲].

برای بهبود دقت و کارایی تحلیل احساسات در زبان فارسی، توسعه مدل‌های پیشرفته و راهکارهایی برای رفع این چالش‌ها ضروری است [۴].

این پژوهش با هدف تحلیل احساسات نظرات کاربران درباره جنبه‌های مختلف تلفن همراه در یک بازارگاه برخط و بررسی فرآیند پیش‌پردازش داده‌ها در زبان فارسی انجام شده است. در این راستا، رویکردهای مختلف تحلیل احساسات بررسی شده و رویکردی مناسب برای تحلیل احساسات و پیش‌پردازش داده‌های فارسی ارائه گردیده است. رویکردهای پیشنهادی شامل شبکه عصبی پیچشی[۲] (CNN)، مدل زبانی برت[۳] (BERT) با تنظیم اختصاصی روی داده‌های پژوهش و مدل زبانی فست‌تکست[۴] هستند. هدف این پژوهش، بهبود دقت و کارایی این مدل‌ها در تحلیل احساسات فارسی است. برای این منظور، مجموعه داده‌ای شامل نظرات کاربران درباره تلفن همراه، با برچسب‌های مثبت، منفی و خنثی بر اساس جنبه‌های مختلف ایجاد شده است. عملکرد مدل‌ها برای هر جنبه به‌صورت جداگانه ارزیابی شده است. همچنین، با بررسی و آزمایش روش‌های افزایش داده‌ها[۵] و متوازن‌سازی داده‌ها[۶]، تلاش شده است تا دقت مدل‌ها بهبود یابد. در نهایت، با پیاده‌سازی شبکه‌های پیشنهادی، تنظیم دقیق فراپارامترها و انتخاب مقادیر بهینه، عملکرد این مدل‌ها روی داده‌های موردنظر ارزیابی شده است.

۲- مبانی نظری و پیشینه تحقیق

رسانه‌های اجتماعی در سال‌های اخیر رشد چشمگیری داشته‌اند. با افزایش روزافزون استفاده از اینترنت، وب به یکی از مهم‌ترین منابع اطلاعاتی تبدیل شده است [۳۹]. میلیون‌ها نفر نظرها و احساسات خود را در فروشگاه‌های اینترنتی، وبلاگ‌ها و شبکه‌های اجتماعی به اشتراک می‌گذارند. حجم گسترده‌ی محتوای تولیدشده توسط کاربران؛ بسترهای اینترنتی و رسانه‌های اجتماعی را به یکی از گسترده‌ترین منبع داده‌ی افکار عمومی تبدیل کرده است. از این رو تحلیل این داده‌ها برای نظارت بر افکار عمومی و کمک به تصمیم‌گیری یک ضرورت است. تحلیل احساسات یکی از روش‌هایی است که برای تحلیل داده‌های تولیدشده توسط کاربران استفاده می‌شود [۵ و ۶].

۲-۱- سطوح تحلیل احساسات

تحلیل احساسات معمولا در سه سطح سند[۷]، جمله[۸] و جنبه[۹] بررسی می‌شود. در سطح سند به بررسی این که کل سند حاوی نظر مثبت یا منفی است پرداخته می‌شود و دسته‌بندی بر اساس احساس و نظر کلی سند صورت می‌گیرد [۷]. سند را می‌توان مجموعه‌ای از جمله‌ها در نظر گرفت و طبقه‌بندی در سطح سند زمانی بهترین عملکرد را دارد که سند توسط یک شخص و یا در رابطه با موضوعی خاص نوشته شده باشد [۸]. در سطح جمله تمرکز بر جمله

[2] Convolutional Neural Network
[3] Bidirectional Encoder Representations from Transformers
[4] FastText
[5] Data Augmentation
[6] Data Balancing
[7] Document Level
[8] Sentence Level
[9] Aspect Level

است و هدف تعیین مثبت، منفی یا خنثی بودن جمله‌ی مورد نظر است [۹]. یکی از معایب تحلیل احساسات در سطح سند این است که تشخیص احساسات متفاوت در مورد موجودیت‌های مختلف دشوار است. در این مواقع تحلیل احساسات در سطح جمله می‌تواند عملکرد بهتری داشته باشد. سطح جنبه، به بررسی جنبه‌ها یا ویژگی‌های گوناگون موجودیت‌ها و تحلیل احساسات مربوط به هر کدام از آن‌ها می‌پردازد و در نتیجه تحلیل دقیق‌تری ارائه می‌دهد [۱۰]. در این سطح از تحلیل احساسات؛ ابتدا موضوعات و موجودیت‌ها و جنبه‌های بیان‌شده در متن شناسایی و استخراج می‌شود، سپس به تحلیل احساس برای هرکدام از جنبه‌ها پرداخته می‌شود. این رویکرد با شناسایی جنبه‌ها و موضوعات بیان‌شده توسط نویسنده، اطلاعات کاملی را در اختیار قرار می‌دهد. در واقع در این سطح مشخص می‌شود که افراد دقیقا چه چیزی را دوست دارند و چه چیزی را دوست ندارند [۱].

در اکثر مواقع، رویکردهای تحلیل احساسات به سه دسته‌ی کلی شامل رویکردهای مبتنی‌بر واژگان[۱۰]، رویکردهای یادگیری ماشین[۱۱] و رویکردهای ترکیبی[۱۲] تقسیم می‌شود. یادگیری ماشین پرکاربردترین رویکرد در تحلیل احساسات است و برای طبقه‌بندی احساسات به الگوریتم‌های یادگیری ماشین و ویژگی‌های زبان متکی است [۵]. در ادامه به بررسی هر کدام از این رویکردها می‌پردازیم.

۲-۲- رویکردهای تحلیل احساسات مبتنی‌بر واژگان

در رویکردهای مبتنی‌بر واژگان، که به آن رویکرد مبتنی‌بر دانش[۱۳] نیز می‌گویند، تحلیل احساسات مبتنی‌بر احساس واژگان و مجموعه‌ای از واژگان با بار احساسی شناخته‌شده و ازپیش تعیین‌شده است. در این روش از شباهت‌های عاطفی کلمات و عبارات استفاده می‌شود و دقت آن به وزن‌های ازقبل‌آموزش‌دیده[۱۴] وابسته است [۱۲ و ۱۳]. رویکرد مبتنی‌بر واژگان در تحلیل احساسات در سطح جمله بسیار کاربردی است. این رویکرد نیازی به داده‌های آموزشی ندارد و از این‌رو، آن را به‌عنوان رویکرد بدون نظارت[۱۵] می‌توان در نظر گرفت. از سوی دیگر، مشکل اصلی این رویکرد وابستگی به حوزه‌ی کاربردی است، زیرا کلمات در حوزه‌های مختلف می‌توانند معانی و مفاهیم متعددی داشته باشند. بنابراین ممکن است یک کلمه مثبت در حوزه‌ای خاص، در حوزه‌ای دیگر مفهوم متفاوتی داشته باشد [۱۳].

۲-۳- رویکردهای تحلیل احساسات مبتنی‌بر یادگیری ماشین

رویکردهای یادگیری ماشین برای طبقه‌بندی قطبیت[۱۶] احساسات (برای مثال مثبت، منفی یا خنثی بودن)، به روش‌های یادگیری نظارت‌شده[۱۷]، یادگیری بدون نظارت، یادگیری نیمه‌نظارتی[۱۸] و یادگیری تقویتی[۱۹] تقسیم می‌شود [۵]. یادگیری نظارت‌شده زمانی استفاده می‌شود که طبقه‌بندی دارای مجموعه مشخصی از کلاس‌ها باشد و نیازمند داده‌های آموزشی دارای برچسب است [۱۴]. روش‌های بدون‌نظارت زمانی مناسب است که برچسب‌گذاری برای مجموعه‌ی داده مقدور نباشد [۱۵]. روش نیمه‌نظارتی را برای مجموعه داده‌های بدون برچسب که شامل برخی از نمونه‌های برچسب‌دار است، می‌توان استفاده کرد. یادگیری تقویتی از مکانیسم‌های آزمون‌وخطا برای کمک به عامل، در تعامل با محیط اطراف، استفاده می‌کند. عامل، بازخوردهایی از محیط می‌گیرد و تجربه‌هایی از محیط کسب می‌کند و از آن‌ها برای به‌دست‌آوردن بیشترین پاداش استفاده می‌کند [۵]. استفاده از رویکردهای یادگیری ماشین معمولا نتایج خوبی را به همراه دارد، ولی برای دستیابی به عملکرد خوب به مجموعه داده‌های آموزشی بزرگ نیاز دارند.

۲-۴- رویکردهای ترکیبی

رویکرد ترکیبی، رویکردهای مبتنی‌بر واژگان و یادگیری ماشین را ترکیب می‌کند. علت اصلی استفاده از رویکرد ترکیبی، بهره‌بردن از دقت بالای رویکردهای یادگیری ماشین و ثبات رویکردهای مبتنی‌بر واژگان و بهره‌گیری از مزایای آن‌ها است [۵ و ۱۶].

۲-۵- یادگیری عمیق در تحلیل احساسات

اصطلاح یادگیری عمیق، به شبکه‌های عصبی با لایه‌های متعدد پرسپترون اشاره دارد که الهام گرفته از شبکه عصبی مغز انسان است. با این معماری، مدل‌های پیچیده‌تری را

[10] Lexicon-Based
[11] Machine Learning
[12] Hybrid
[13] Knowledge-Based
[14] Pre-Learned
[15] Unsupervised
[16] Polarity
[17] Supervised Learning
[18] Semi-Supervised Learning
[19] Reinforcement Learning

روی مجموعه داده‌ای بسیار بزرگ می‌توان آموزش داد و نتایج بهتری تولید کرد [۵]. در سال‌های اخیر، تحلیل احساسات مبتنی‌بر روش‌های یادگیری عمیق به‌عنوان روشی قدرتمند برای تحلیل احساسات دقیق مطرح شده است [۱۷]. شبکه عصبی بازگشتی[۲۰]، شبکه عصبی پیچشی و حافظه‌طولانی‌کوتاه‌مدت[۲۱]، رایج‌ترین مدل‌های یادگیری عمیق در تحلیل احساسات هستند [۱۸].

۲-۵-۱- شبکه عصبی پیچشی

شبکه عصبی پیچشی نوع خاصی از شبکه عصبی پیشخور[۲۲] است که در ابتدا در حوزه بینایی کامپیوتری به‌کار می‌رفت؛ اما امروزه در زمینه‌های مختلف مانند سیستم‌های توصیه‌گر و پردازش زبان طبیعی[۲۳] به نتایج موفقی دست یافته است [۵ و ۱۹]. شبکه عصبی پیچشی شامل یک لایه ورودی، یک لایه خروجی و یک لایه پنهان است. در معماری این شبکه، لایه پنهان شامل چندین لایه پیچشی، لایه ادغام[۲۴] و لایه کاملا متصل[۲۵] است [۲۰]. لایه ورودی وظیفه دریافت داده و انتقال آن به لایه‌های بعدی را دارد. لایه پیچشی برای تشخیص الگوها و استخراج ویژگی‌ها در داده‌های ورودی طراحی‌شده است و محاسبات شبکه عصبی در این لایه انجام می‌شود. اندازه فضای ویژگی که در لایه پیچشی به‌دست‌آمده، توسط لایه ادغام کاهش می‌یابد و اطلاعات مهم حفظ می‌شود. پس از استخراج ویژگی‌ها از طریق لایه‌های پیچشی و ادغام، از لایه‌های کاملا متصل به‌عنوان لایه‌های پایانی برای اتصال ویژگی‌های استخراج‌شده و تصمیم‌گیری نهایی، با توجه به اطلاعات به‌دست‌آمده، استفاده می‌شود. برای مثال در مسائل دسته‌بندی چندکلاسه، با استفاده از یک تابع فعال‌ساز، احتمال مربوط به هر کلاس محاسبه می‌شود. در نهایت در لایه خروجی، نتایج نهایی مدل به‌دست می‌آید [۱۹ و ۲۱].

۲-۶- تحلیل احساسات مبتنی‌بر مدل‌های زبانی

در سال‌های اخیر تحقیقات گسترده‌ای برای ساخت مدل‌های مختلف تحلیل احساسات برای زبان انگلیسی، فارسی و سایر زبان‌ها با استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق انجام‌شده و مدل‌سازی زبان محبوبیت پیدا کرده است [۱۷]. تحلیل احساسات در هر زبان به یک سری از پیش نیازهای مشخص، وابسته است و استفاده‌ی مستقیم از روش‌ها، ابزارها و منابع توسعه‌یافته برای زبان انگلیسی در فارسی با محدودیت‌هایی مواجه است. بنابراین، تحلیل احساسات در زبان فارسی به دلیل دارا بودن ویژگی‌های خاص این زبان، نسبت به زبان انگلیسی، نیازمند اتخاذ روش‌ها و مدل‌های منحصربه‌فرد است [۲]. یکی از انواع این مدل‌ها، که مبتنی‌بر ارزیابی وابستگی بین توالی‌های ورودی/خروجی است، مدل ترنسفورمر نام دارد. این مدل به رمزگذار و رمزگشا وابسته است. رمزگذار دنباله ورودی را می‌گیرد و آن را به برداری با ابعاد بالاتر نگاشت می‌کند. سپس این بردار توسط رمزگشا به دنباله‌ای از خروجی نگاشت می‌شود. از جمله مدل‌سازی‌های زبان از-پیش‌آموزش‌دیده[۲۶] مبتنی‌بر مدل ترنسفورمر، مدل‌های برت [۲۵] و GPT [۲۲] است و به‌عنوان مدل‌های پرکاربرد و مؤثر در حوزه مدل‌سازی زبان شناخته می‌شوند [۲۳]. برای زبان فارسی نیز چندین مدل جاسازی کلمات[۲۷] از جمله Word2Vec، GloVe و فست‌تکست ارائه شده است [۲۴].

۲-۶-۱- مدل زبانی برت

برت یک چارچوب یادگیری ماشین منبع‌باز و یک مدل زبانی قدرتمند برای پردازش زبان طبیعی است. برت، یک مدل ازپیش‌آموزش‌دیده و دوطرفه و مبتنی‌بر ترنسفورمر است که در سال ۲۰۱۸ معرفی شد [۲۵]. در واقع برت یک مدل یادگیری عمیق است که در آن هر عنصر خروجی به هر عنصر ورودی متصل می‌شود. وزن‌های بین این عناصر، به‌صورت پویا و بر اساس اتصال آن‌ها محاسبه می‌شود [۲۶]. مدل زبان آموزشی دوطرفه در استخراج ویژگی‌ها و تفسیر متن، بهتر از مدل زبان یک‌طرفه عمل می‌کند. در واقع در معماری دو طرفه متن به‌صورت دوسویه، از اول تا آخر و از آخر به اول، پردازش می‌شود. برای دستیابی به نمایش برداری بهتر، مدل برت از ساختار ترنسفورمر برای یادگیری اطلاعات زمینه‌ای کلمات ورودی استفاده می‌کند. توانایی تجزیه و تحلیل متن به‌صورت دوطرفه، جلورو[۲۸] و عقب‌رو[۲۹]، به این نوع مدل‌ها اجازه می‌دهد تا دانش قبلی خود را به کار خاصی اختصاص دهند؛ دانشی که از طریق یک مرحله

[20] Recurrent Neural Network (RNN)
[21] Long Short-Term Memory (LSTM)
[22] Feedforward Neural Network
[23] Natural Language Processing
[24] Pooling
[25] Fully Connected
[26] Pre-Trained
[27] Word Embeddings
[28] Forward
[29] Backward

طولانی از قبل‌آموزش‌دیده، در مجموعه‌های عظیم به‌دست آمده است. در واقع، شبکه را با استفاده از دو روش استخراج ویژگی و تنظیم دقیق می‌توان اختصاصی کرد.

۲-۶-۲- مدل زبانی فست‌تکست

مدل فست‌تکست [۲۸] روشی پیشرفته در پردازش زبان طبیعی برای طبقه‌بندی متن و توسعه‌یافته توسط فیس‌بوک است. این روش برای پردازش متن‌های طولانی، با تعداد زیاد کلاس یا برچسب، بسیار کارآمد است. در این روش، مفاهیم بسته‌ی کلمات[۳۰] و جاسازی کلمات ترکیب می‌شود و مزایایی مانند سرعت بالا و دقت معقول را ارائه می‌دهد [۲۹]. در ادامه مراحل اصلی فست‌تکست برای طبقه‌بندی متن آمده است.

- ساخت لغت‌نامه و جاسازی کلمات: مدل فست‌تکست از الگوریتم Word2Vec برای ایجاد جاسازی کلمات استفاده می‌کند. در این مرحله، هر کلمه به برداری عددی تبدیل می‌شود که ویژگی‌های مختلف زبان را مشخص می‌کند. این نمایش برداری، بر اساس معانی مشترک کلمات در میان متن ایجاد می‌شود.
- ساخت n-gram: در فست‌تکست علاوه بر تک‌واژه‌ها، از n-gram نیز استفاده می‌شود. n-gram مجموعه‌ای از n کلمه‌ی متوالی در متن است. این مفهوم به تحلیل و فهم متن‌ها، بر اساس رابطه و ترتیب عناصر متوالی و درک ارتباطات بین کلمات در چارچوبی خاص از متن کمک می‌کند. استفاده از n-gram در پردازش زبان طبیعی بسیار مفید است. به‌عنوان مثال، در حوزه‌ی متن‌کاوی و طبقه‌بندی متن، n-gram در زمینه‌ی تشخیص الگوها و روابط بین کلمات و توکن‌ها و همچنین تحلیل دقیق‌تر متن کمک‌کننده است.
- ساخت بردارهای نمایش متن: ساخت بردارهای نمایش متن گامی اساسی در بسیاری از حوزه‌های کاربردی پردازش زبان طبیعی، از جمله طبقه‌بندی متن با استفاده از روش‌هایی مانند فست‌تکست است. این فرآیند شامل تبدیل محتوای متنی به بردارهای عددی است که الگوریتم‌های یادگیری ماشین قادر به درک و پردازش آن‌ها هستند. این بردارها، ویژگی‌های اساسی متن را به‌گونه‌ای ثبت می‌کنند که به مدل امکان پیش‌بینی یا انجام وظایف مختلف پردازش زبان طبیعی را می‌دهند. در فست‌تکست برای ساخت بردار، ابتدا تمام ویژگی‌های تعبیه‌شده مربوط به کلمات در متن جمع‌آوری می‌شوند. سپس با میانگین‌گیری از تمام این ویژگی‌ها، یک بردار نهایی برای متن به‌دست می‌آید.
- آموزش مدل: با استفاده از بردارهای نمایش متن و برچسب‌های موجود، مدل برای طبقه‌بندی آموزش داده می‌شود. این مدل می‌تواند از الگوریتم‌هایی مانند شبکه عصبی پیچشی استفاده کند.

به‌طور خلاصه، فست‌تکست روشی قدرتمند برای طبقه‌بندی متن است و از ویژگی‌های جاسازی و ترکیب کلمات برای دسته‌بندی دقیق و سریع متن‌ها در کلاس‌های مختلف استفاده می‌کند [۲۹ و ۳۰].

۲-۷- پیشینه تحقیق

تحلیل احساسات یکی از مسائل مهم در زمینه علوم داده و پردازش زبان طبیعی است که در سال‌های اخیر توجه محققان، صنعت و جوامع علمی را به خود جلب کرده است و تأثیر مهمی در تصمیم‌گیری‌ها، توسعه محصولات، بازاریابی، ابزارهای پشتیبانی از مشتری و حتی سیاست‌گذاری دارد.

جورک و همکاران [۳۲] الگوریتمی جدید برای تحلیل احساسات مبتنی‌بر واژگان ارائه کردند که تمرکز اصلی آن تحلیل محتوای توییتر است. این الگوریتم، از دو جزء کلیدی شامل نرمال‌سازی احساسات و تابع ترکیبی مبتنی‌بر شواهد[۳۱] تشکیل شده است. از این الگوریتم برای تخمین شدت احساسات به‌جای برچسب مثبت و منفی و طبقه‌بندی احساسات استفاده شده است و از مجموعه‌ی داده‌ای شامل ۱/۶ میلیون توییت استفاده کردند.

سینگلا و همکاران [۳۳] از الگوریتم‌های یادگیری ماشین برای طبقه‌بندی احساسات استفاده کردند. آن‌ها، داده‌های جمع‌آوری‌شده از وب‌سایت آمازون را با استفاده از روش‌های نیوبیز[۳۲] و ماشین‌بردارپشتیبان[۳۳] به نظرهای مثبت و منفی دسته‌بندی کردند. در این تحقیق، روش ماشین‌بردار-پشتیبان با دقت ۸۱/۷۵ درصد بهترین عملکرد را داشت.

ابراهیمی و همکاران [۳۴] روشی نظارت‌شده برای توسعه‌ی مجموعه‌ی واژگان با بار احساسی مشخص با استفاده از استخراج ویژگی‌ها برای زبان فارسی پیشنهاد کردند. در این

[30] Bag of Words (BoW)
[31] Evidence-Based
[32] Naïve Bayes
[33] Support Vector Machine

پژوهش، از نظرهای جمع‌آوری‌شده از یک سایت فروش آنلاین به‌عنوان مجموعه‌ی داده استفاده شد. این مجموعه شامل ۷،۵۰۰ نظر در زمینه‌ی دوربین دیجیتال، لپ تاپ، تلویزیون، تبلت و تلفن همراه است که به‌صورت دستی جمع‌آوری شده و از آن برای انتخاب ویژگی و ایجاد لیستی از کلمات احساسی استفاده شده است. برای ارزیابی عملکرد رویکرد پیشنهادی، از روش ماشین‌بردارپشتیبان استفاده شد و دقت ۸۰ درصد به‌دست‌آمد.

ارمنی و همکارانش [۳۵] رویکردی ترکیبی مبتنی‌بر روش ماشین‌بردارپشتیبان و جنگل تصادفی پیشنهاد کردند. داده‌های این پژوهش از وب‌سایت آمازون جمع‌آوری شد و نتایج آن نشان‌داد که رویکرد ترکیبی با دقت ۸۳/۴ عملکرد بهتری از سایر الگوریتم‌ها به‌صورت جداگانه داشت.

کیم و همکاران [۳۶] شبکه عصبی پیچشی را برای طبقه‌بندی احساسات در کار خود پیشنهاد کردند. آن‌ها از طریق آزمایش‌هایی با سه مجموعه داده‌ی شناخته‌شده، نشان دادند که استفاده از لایه‌های پیچشی متوالی برای متن‌های نسبتا طولانی مؤثرتر است و عملکرد بهتری از سایر مدل‌های یادگیری عمیق دارد.

سانی و همکاران [۳۷] معماری جدیدی به نام TextConvoNet و مبتنی‌بر شبکه عصبی پیچشی برای مسائل طبقه‌بندی متن دوکلاسه و چندکلاسه ارائه کردند. آن‌ها با استفاده از این مدل ویژگی‌های درون جمله‌ای و بین جمله‌ای را با، n-gram از داده‌های ورودی استخراج می‌کنند. نتایج تجربی حاصل از این پژوهش نشان می‌دهد که مدل ارائه‌شده نسبت به سایر مدل‌های مورد استفاده برای طبقه‌بندی متن، عملکرد بهتری دارد.

جانگ و همکاران [۳۸] مدلی ترکیبی از حافظه‌کوتاه‌مدت-دوطرفه[۳۴] و شبکه عصبی پیچشی مبتنی‌برتوجه[۳۵] را پیشنهاد کردند. برای این کار از مجموعه داده‌ی مربوط به نظرهای فیلم‌ها در IMDB[۳۶] استفاده شد. نتایج حاصل از مدل ترکیبی پیشنهادی، با دقت ۸۷/۳۳ درصد، نشان‌دهنده‌ی بهبود نتایج نسبت به مدل‌های حافظه-طولانی‌کوتاه‌مدت و شبکه عصبی پیچشی است.

همانطور که قبلا گفته شد؛ تحلیل احساسات در سطح‌های مختلف از جمله سطح سند، جمله و جنبه مورد بررسی قرار می‌گیرد. این سطوح تحلیل احساسات در جملات و سندها، با استفاده از روش‌های پردازش زبان طبیعی و الگوریتم‌های مختلف، به شناسایی الگوهای احساسی می‌پردازند. طبقه‌بندی احساسات در سطح سند موضوعی اساسی در تجزیه و تحلیل احساسات است و برای درک محتوای تولیدشده توسط کاربران در شبکه‌های اجتماعی یا بررسی محصول بسیار مهم است.

تانگ و همکاران [۴۰] با مطرح‌کردن تحلیل احساسات در سطح سند به عنوان یک چالش، یک مدل شبکه عصبی برای یادگیری اسناد متوالی، برای طبقه‌بندی احساسات معرفی کردند. روش آن‌ها بر اساس اصل ترکیب‌بندی است که بیان می‌کند معنای عبارتی طولانی مثل یک جمله یا یک سند، به معانی اجزای تشکیل‌دهنده آن بستگی دارد. آن‌ها از رویکردهای شبکه عصبی پیچشی، حافظه‌طولانی‌کوتاه‌مدت و شبکه عصبی بازگشتی استفاده کردند. در این پژوهش، طبقه‌بندی احساسات در سطح سند روی چهار مجموعه داده در مقیاس بزرگ انجام شد. نتایج تجربی نشان می‌دهد که مدل پیشنهادی عملکرد بهتری نسبت به چندین الگوریتم دیگر داشت. تحلیل احساسات در سطح جمله یکی از سطوح اصلی تحلیل احساسات است.

تحقیقات زیادی در این زمینه، برای شناسایی قطبیت جملات، بر اساس نشانه‌های زبانی استخراج شده از محتوای متن صورت گرفته است. یکی از چالش‌های مطرح در این سطح این است که انواع مختلف جملات می‌توانند احساسات متفاوتی را بیان کنند. به عنوان مثال، در جمله خبری "خوب است"، قطبیت احساس مثبت است. در عین حال در جمله پرسشی "آیا خوب است؟" قطبیت احساس مبهم است.

چن و همکاران [۹] یک روش تقسیم‌وغلبه[۳۷] ارائه کردند که ابتدا جملات را به انواع مختلف طبقه‌بندی می‌کنند؛ سپس تحلیل احساسات را به طور جداگانه روی جملات هر نوع انجام می‌دهند. آن‌ها با بررسی رابطه بین تعداد اهداف نظری بیان‌شده و احساسات بیان‌شده در یک جمله، چارچوبی جدید برای بهبود تحلیل احساسات از طریق طبقه‌بندی نوع جمله پیشنهاد کردند. اهداف نظری، به هر موجودیت یا جنبه‌ای از جمله اشاره دارد که نظری در مورد آن ابراز شده است. آن‌ها در کار خود از مدلی مبتنی‌بر شبکه عصبی برای طبقه‌بندی جملات به سه نوع، با توجه به تعداد اهداف

[34] Bi-LSTM
[35] Attention-Based
[36] Internet Movie Database
[37] Divide and Conquer

ظاهرشده در یک جمله، استفاده کردند. سپس هر گروه از جملات به‌طور جداگانه، برای طبقه‌بندی احساسات، به‌عنوان ورودی شبکه عصبی پیچشی در نظر گرفته شد. نتایج تجربی حاصل از این پژوهش نشان می‌دهد که طبقه‌بندی نوع جمله می‌تواند عملکرد تحلیل احساسات در سطح جمله را بهبود بخشد. همچنین رویکردپیشنهادی به نتایج مطلوبی در چندین مجموعه داده معیار رسید.

در سطح جنبه، یافتن احساسات با توجه به جنبه‌های خاص موجودیت‌ها صورت می‌گیرد. از آن‌جا که ممکن است در یک متن، احساسی واحد نسبت به موضوعی منتقل نشود، نیاز به شناخت دقیق‌تر نظرها و احساسات، که به‌عنوان تحلیل احساسات مبتنی‌بر جنبه شناخته می‌شود، در سال‌های گذشته مورد توجه زیادی قرار گرفته است [۴۱].

الگریوتی و همکاران [۴۲] با هدف کمک به نهادهای دولتی برای کسب دیدگاه جامع‌تر از نگرش افراد، یک رویکرد ترکیبی تحلیل احساسات مبتنی‌بر جنبه را پیشنهاد کردند که دامنه واژگان و قوانین را برای تجزیه و تحلیل نظرهای برنامه‌های هوشمند، یکپارچه می‌کند. هدف مدل پیشنهادی استخراج جنبه‌های مهم از این نظرها و طبقه‌بندی احساسات مربوط به آن‌ها است. با توجه به نتایج گزارش شده، دقت استخراج جنبه با درنظرگرفتن جنبه‌های ضمنی به طور قابل توجهی بهبود یافته است. همچنین رویکرد پیشنهادی، در طبقه‌بندی احساسات، از روش‌های یادگیری ماشین همچون ماشین‌بردارپشتیبان بهتر عمل کرد.

ماجومدر و همکاران [۴۱] تحلیل احساسات سطح جنبه را به‌صورت دو بخش متمایز استخراج جنبه و برچسب‌گذاری جنبه‌ها با قطبیت احساسات در نظر گرفتند. با وجود اینکه این دو کار متمایز هستند، اما ارتباط زیادی با هم دارند. رویکرد پیشنهادی این فرضیه را مطرح می‌کند که انتقال دانش از یک مدل استخراج جنبه ازپیش‌آموزش‌دیده، به عملکرد مدل‌ها در طبقه‌بندی قطبیت احساسات می‌تواند کمک کند. آن‌ها بر اساس این فرضیه، جاسازی کلمات را در طول استخراج جنبه به‌دست آورند؛ سپس آن را به‌عنوان ورودی مدل‌های طبقه‌بندی قطبیت احساسات در نظر گرفتند. نتایج تجربی نشان داد که اطلاعات اضافه‌شده، به‌طور قابل توجهی عملکرد مدل‌های پایه در طبقه‌بندی احساسات را بهبود بخشیده است.

روستائی و همکاران به تحلیل احساسات کاربران در زبان فارسی مبتنی‌بر ترکیب روابط معنایی و جنگل تصادفی پرداختند. در این پژوهش، نظرات کاربران سایت دیجی‌کالا مورد بررسی قرار گرفته است. ابتدا عملیات پاکسازی داده‌ها صورت گرفته و سپس ویژگی‌ها بر اساس روابط معنایی فست‌تکست استخراج شده است. در مرحله بعد، عملیات کاهش ویژگی توسط شبکه‌های یادگیری عمیق انجام شده و در نهایت، برای طبقه‌بندی نظرات از الگوریتم جنگل تصادفی استفاده شده است. نتایج نشان‌دهنده دقت ۹۸/۵ درصد، صحت ۹۷ درصد، فراخوان ۹۸ درصد و معیار F1 برابر با ۹۷ درصد می‌باشد [۴۳].

قاسمپور مرزبالی از تحلیل احساسات مبتنی‌بر جنبه با استفاده از برت استفاده کرد. این مطالعه به تحلیل احساسات ریزدانه (ABSA) پرداخته است. برای مقابله با محدودیت اندازه مجموعه داده‌های آموزشی، از تولید متن مبتنی‌بر برت همراه با الگوریتم‌های فیلتر متن استفاده شده است. این رویکرد به بهبود کیفیت مجموعه داده‌ها و افزایش عملکرد مدل‌ها در طبقه‌بندی احساسات سطح جنبه منجر شده است [۴۴].

فائزه فروتن و محمد ربیعی با هدف بهبود استخراج ویژگی‌ها از نظرات فارسی و افزایش دقت تحلیل احساسات، چارچوبی جدید برای تحلیل احساسات در سطح جمله ارائه می‌دهند. این چارچوب مبتنی بر مدل‌های برت، CNN-BiLSTM و طبقه‌بندی‌کننده XGBoost است. نتایج نشان‌دهنده دقت ۹۳/۷۴ درصد در طبقه‌بندی احساسات متون فارسی است که نشان می‌دهد ترکیب مدل‌های مذکور می‌تواند به بهبود دقت تحلیل احساسات در زبان فارسی منجر شود [۴۵].

لی و همکاران به تحلیل لحن و احساسات نظرات شبکه‌های اجتماعی در پلتفرم‌های رسانه‌ای جدید با استفاده از مدل برت پرداختند. در این مطالعه، مدل برت به دلیل قابلیت‌های رمزگذاری دوطرفه و درک متنی‌اش، برای تحلیل احساسات و لحن نظرات در پلتفرم‌های رسانه‌ای جدید انتخاب شده است. از طریق فرآیند پیش‌آموزش و تنظیم دقیق، نگرش‌ها و قطبیت‌های احساسی نظرات به‌همراه ویژگی‌های لحنی مانند شادی، خشم و طعنه به‌دقت شناسایی شدند. تحلیل دقیق لحن و احساسات معنایی نظرات در پلتفرم‌های رسانه‌ای جدید، درک عمیقی از ترجیحات کاربران و روندهای افکار عمومی فراهم می‌کند که می‌تواند به بهینه‌سازی توصیه‌های محتوا، بهبود

تجربیات کاربری و افزایش کارایی عملیاتی این پلتفرم‌ها کمک کند. نتایج نشان می‌دهد که مدل برت قادر است به‌طور دقیق نگرش‌های احساسی و ویژگی‌های لحنی نظرات را شناسایی کند [۴۶].

طلعت چهار مدل عمیق مبتنی بر ترکیب برت با الگوریتم‌های BiLSTM و BiGRU را پیشنهاد می‌دهد. این مدل‌ها بر روی سه مجموعه داده آموزش داده شدند و نتایج نشان داد که ترکیب برت با BiLSTM وBiGRU می‌تواند عملکرد بهتری نسبت به استفاده تنها از برت داشته باشد [۴۷].

مانوئل-ایلی و همکاران به بررسی جامع الگوریتم تحلیل احساسات با استفاده از مدل برت پرداخته و مبانی نظری، معیارهای ارزیابی، یافته‌ها و تحلیل مقایسه‌ای را ارائه می‌دهد. نویسندگان با استفاده از مدل برت، الگوریتمی برای تحلیل احساسات توسعه داده‌اند. این الگوریتم قادر است با دقت بالایی احساسات موجود در متون را شناسایی کند و در کاربردهای مختلفی مانند پیش‌بینی قطبیت احساسات و پیش‌بینی احساسات مورد استفاده قرار گیرد. این مطالعه نشان می‌دهد که استفاده از مدل‌های مبتنی بر یادگیری عمیق، به‌ویژه برت، می‌تواند بهبود قابل‌توجهی در دقت و کارایی سیستم‌های تحلیل احساسات ایجاد کند [۴۸].

در جدول ۱، مقایسه پژوهش‌های تحلیل احساسات در سال‌های اخیر آمده است.

جدول ۱- مقایسه پژوهش‌های تحلیل احساسات

پژوهشگر/سال	روش تحلیل احساسات	داده‌های مورد استفاده	الگوریتم‌های یادگیری ماشین	دقت مدل
جانگ و همکاران [۳۸] (۲۰۲۰)	یادگیری عمیق ترکیبی	داده‌ی مربوط به نظرهای فیلم‌ها در IMDB	مدلی ترکیبی از حافظه‌کوتاه-مدت‌دوطرفه و شبکه عصبی پیچشی مبتنی‌برتوجه	دقت ۸۷/۳۳ درصد
روستائی و همکاران [۴۳] (۱۴۰۱)	ترکیب روابط معنایی و جنگل تصادفی	نظرهای سایت دیجی‌کالا	جنگل تصادفی	۹۸/۵ درصد
قاسمپور مرزبالی [۴۴] (۱۴۰۳)	ABSA مبتنی بر برت	مجموعه داده‌های ABSA	برت و تولید متن	بهبود عملکرد مدل‌ها
فائزه فروتن و محمد [۴۵] ربیعی (۲۰۲۳)	برت، CNN-BiLSTM و XGBoost	نظرهای متون فارسی	برت، CNN-BiLSTM، XGBoost	۹۳/۷۴ درصد
لی و همکاران [۴۶] (۲۰۲۴)	برت برای تحلیل لحن و احساسات	نظرهای شبکه‌های اجتماعی در پلتفرم‌های جدید	برت	تشخیص دقیق نگرش‌های احساسی
طلعت [۴۷] (۲۰۲۳)	ترکیب برت با BiLSTM و BiGRU	سه مجموعه داده مختلف	برت، BiLSTM، BiGRU	بهبود نسبت به برت خالص
مانوئل-ایلی و همکاران [۴۸] (۲۰۲۳)	تحلیل جامع با برت	متون با کاربردهای مختلف	برت	دقت بالا در کاربردهای مختلف
پژوهش حاضر	تحلیل احساسات جنبه‌محور تلفن همراه با روش‌های متوازن‌سازی و افزایش داده‌ها	۶۱۸۰ نظر درباره تلفن همراه از دیجی کالا	CNN،برت با تنظیم اختصاصی، فست‌تکست	بهبود دقت نسبت به کارهای گذشته و متوازن‌سازی داده‌ها

۳- روش پیشنهادی

در این بخش روش پیشنهادی برای تحلیل احساسات روی نظرهای کاربران با استفاده از روش‌های یادگیری عمیق و مدل‌های ارائه‌شده برای زبان فارسی بیان شده است. روند کلی این پژوهش، در شکل ۱ نمایش داده شده است.

۳-۱- پیش‌پردازش داده‌ها

یکی از اولین گام‌ها در مسائل پردازش زبان طبیعی، پیش‌پردازش داده‌ها است و برای دستیابی به عملکرد بهتر مدل‌های یادگیری، از اهمیت زیادی برخوردار است. کارهای انجام‌شده برای پیش‌پردازش داده‌ها به شرح زیر است:

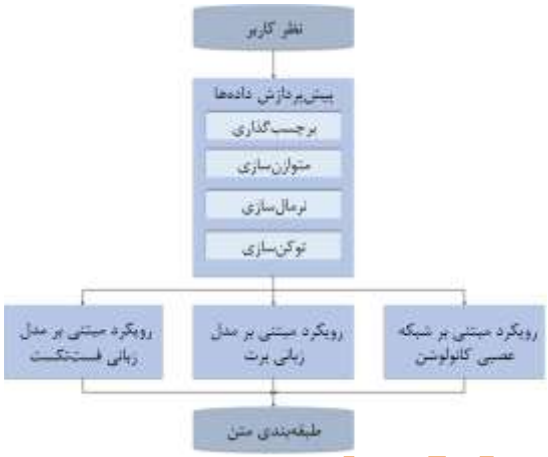

شکل ۱- رویکرد پیشنهادی برای تحلیل احساسات مبتنی‌بر جنبه

۳-۱-۱- برچسب‌گذاری

داده‌ها در این پژوهش، نظرهای مربوط به تلفن همراه است. این نظرها به سه دسته‌بندی مختلف بر اساس جنبه‌های مربوط به دوربین، باتری و قیمت تقسیم و جداگانه برچسب‌گذاری شده است. با توجه به نقاط قوت و ضعف مطرح‌شده توسط کاربر و یک سری کلمات کلیدی مربوط به جنبه‌های انتخاب‌شده، برچسب‌گذاری نظرها در سه کلاس مثبت، منفی و خنثی انجام شده است. برای مثال جمله‌ی "این گوشی قیمت مناسبی دارد و کیفیت باتری خوب است"، در جنبه‌های قیمت و باتری دارای برچسب مثبت و در جنبه دوربین دارای برچسب خنثی است.

۳-۱-۲- متوازن‌سازی

متوازن‌سازی داده‌ها در مدل‌های یادگیری ماشین، هنگامی که داده‌هایی با کلاس‌های نامتوازن داریم، از اهمیت زیادی برخوردار است. ضرورت انجام متوازن‌سازی داده‌ها در مدل‌های یادگیری عمیق برای جلوگیری از بیش‌برازش[۳۸]، عملکرد بهتر در کلاس‌های با فراوانی کمتر و تعادل در ارزیابی است.

۳-۱-۳- نرمال‌سازی

یکی از مراحل ضروری در پیش‌پردازش داده‌ها، هنگام کار با داده‌های متنی، نرمال‌سازی متن است. این مرحله شامل تبدیل متن به فرمی استاندارد و متعارف برای افزایش دقت در پردازش زبان طبیعی است. در متن فارسی، به علت وجود اشکال گوناگون در نوشتار، برخی از کلمات یا حروف به چندین شکل مختلف نمایش داده می‌شوند. در نرمال‌سازی متن، اصلاح فاصله‌ها در پیشوندها و پسوندها، حذف اعراب، حذف تکرارهای زائد حروف، جایگزینی برخی از حروف و نشانه‌ها با حروف و نشانه‌های فارسی و جایگزینی اعداد انگلیسی با معادل فارسی انجام می‌گردد.

۳-۱-۴- توکن‌سازی

توکن‌سازی مرحله‌ای اساسی در پردازش زبان طبیعی است که متن را به واحدهای معنادار تقسیم می‌کند. این واحدها شامل کلمات، نشانه‌های نگارشی، اعداد و یا واحدهای معنادار دیگر در زبان است. در توکن‌سازی چند نکته حائز اهمیت است، این موارد عبارتند از:

- حفظ معنا: هدف اصلی توکن‌سازی، حفظ معنا در متن است. توکن‌ها باید واحدهای معنادار متن را به نحوی نمایش دهند که تحلیل صحیح از آن‌ها امکان پذیر باشد.
- کار با علائم نگارشی: نشانه‌های نگارشی به‌عنوان توکن‌های جداگانه در نظر گرفته می‌شوند. این امر برای کارهایی مانند تحلیل احساسات، که نشانه‌ها می‌توانند بر تحلیل احساس جمله مؤثر باشند، مهم است.
- پیشوندهای غیر قابل شکستن: در زبان فارسی، پیشوندهایی مثل "می" در "می‌خواهم" غیرقابل شکستن هستند و باید به کلمه‌ای دیگر چسبیده باشند.
- کنترل فضاها: توکن‌سازی باید فضاهای غیرضروری را حذف و متن را در مکان‌های مناسب، بین کلمات و نشانه‌های نگارشی، تقسیم کند.

۳-۲- رویکرد مبتنی‌بر شبکه عصبی پیچشی

برای تحلیل احساسات با استفاده از شبکه عصبی پیچشی، پس از توکن‌سازی داده‌ها و تبدیل متن به عدد، از لایه جاسازی[۳۹] برای تبدیل این اعداد به بردارهای عددی استفاده می‌شود. این لایه برای کار با داده‌های متنی استفاده می‌شود. سپس با استفاده از لایه جاسازی، این شناسه‌ها به بردارهای عددی با ابعاد مشخص تبدیل می‌شوند. در مرحله بعد، با اعمال لایه‌های پیچشی با اندازه‌ها و تعداد فیلترهای

[38] Overfitting

[39] Embedding Layer

مختلف، عملیات پیچشی روی بردارهای ورودی انجام شده و ویژگی‌های مختلف استخراج می‌شود. انتخاب چندین لایه پیچشی با فیلترهای افزایشی، برای دستیابی به ویژگی‌های سلسله مراتبی در داده‌های ورودی دارای اهمیت است. هر لایه پیچشی دارای اندازه فیلتر ۱۲۸ است و از تابع فعال‌سازی Relu استفاده می‌کند. لایه Conv1D یک نوع لایه‌ی پیچشی است که برای پردازش داده‌های یک‌بعدی (مانند پردازش متن و دنباله‌ها) استفاده می‌شود و الگوها و ویژگی‌های مهم در دنباله‌های متنی مانند تشخیص احساسات را استخراج می‌کند. پس از هر لایه پیچشی، عملیات ادغام در خروجی لایه‌های پیچشی برای انتخاب ویژگی‌های مهم از بردارهای پیچشی صورت می‌گیرد. در نهایت از لایه‌های کاملا متصل برای ترکیب و تبدیل ویژگی‌های استخراج‌شده به خروجی نهایی استفاده می‌شود. لایه چگال[40]، یک لایه کاملا متصل در شبکه عصبی عمیق است. این لایه به‌عنوان لایه پردازش اصلی در شبکه عمل می‌کند و وظیفه تبدیل ورودی‌ها به خروجی‌های پیش‌بینی‌شده را دارد. در واقع این لایه برای بهبود ویژگی‌ها و کاهش بُعد، به مرحله طبقه‌بندی نهایی اضافه می‌شود و نقش حیاتی در تجمیع دانش به‌دست‌آمده از لایه‌های قبلی را ایفا می‌کند. در آخرین مرحله، از یک لایه چگال با تابع فعال‌سازی Softmax استفاده‌شده تا احتمالات خروجی برای طبقه‌بندی نهایی محاسبه شود. همچنین، در روند ساخت مدل پس از مرحله استخراج ویژگی، از یک لایه حذف تصادفی[41] جهت جلوگیری از بیش‌برازش مدل و افزایش عمومیت آن استفاده شده است. در شکل ۲ ساختار شبکه‌ی عصبی پیچشی پیشنهادی نمایش داده شده است.

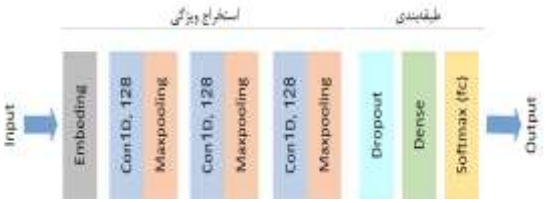

شکل ۲- ساختار شبکه عصبی پیچشی پیشنهادی

۳-۳- رویکرد مبتنی‌بر مدل زبانی برت

مدل برت یک مدل از قبل آموزش‌دیده است که روی مجموعه بزرگی از داده‌ها آموزش داده می‌شود، سپس برای یک کار خاص تنظیم دقیق می‌شود. تنظیم دقیق برت، فرآیند انطباق مدل برت از قبل آموزش‌دیده برای یک کار خاص و تنظیم پارامترهای آن با داده‌های جدید است. این فرآیند شامل افزودن یک لایه در بالای رمزگذار و آموزش مدل با یک تابع هزینه و بهینه‌ساز مناسب است. برای تحلیل احساسات با استفاده از مدل برت، پس از پیش‌پردازش داده‌ها، عملیات توکن‌سازی با استفاده از توکن‌ساز برت انجام می‌شود. این توکن‌سازی کمک می‌کند تا متن به توکن‌های واحد تبدیل شود و برای ورودی مدل برت قابل قبول باشد. پس از آن از یک مدل برت از قبل آموزش دیده استفاده می‌شود و مدل برت روی داده‌ها آموزش داده می‌شود. در نهایت مدل آموزش‌دیده، ارزیابی و معیارهای انتخاب‌شده روی داده‌های آزمایشی برای ارزیابی عملکرد مدل محاسبه می‌شود.

۳-۴- رویکرد مبتنی‌بر مدل زبانی فست‌تکست

برای مدل فست‌تکست، با استفاده از داده‌های پیش‌پردازش‌شده، مدل آموزش داده می‌شود. در این مرحله، مدل روی داده‌های آموزشی، آموزش داده می‌شود و وزن‌های مربوط برای کلمات استخراج می‌شوند. با بهره‌گیری از الگوریتم Word2Vec، برای ایجاد جاسازی کلمات و با استفاده از معانی مشترک کلمات، بردارهای عددی برای هر کلمه ایجاد می‌شود. پس از ساخت این بردارها، مدل برای طبقه‌بندی متن آموزش داده می‌شود. داده‌های مورد استفاده برای آموزش باید شامل برچسب‌ها و داده‌های آموزش در یک قالب مشخص باشد. برای آموزش مدل پارامترهای مختلف از جمله نرخ یادگیری[42]، تعداد دوره[43]های آموزش و مقدار n-gram قابل تنظیم است. همچنین از تابع هزینه مناسب برای طبقه‌بندی متن در فرآیند آموزش استفاده می‌شود. پس از آموزش، مدل ارزیابی و میزان دقت و عملکرد آن روی داده‌های آزمایشی محاسبه می‌شود.

۴- پیاده‌سازی و ارزیابی

۴-۱- فراهم‌سازی داده‌ها

داده‌های مورد استفاده در اینجا شامل نظرهای فارسی کاربران در مورد تلفن همراه، به همراه نقاط قوت و ضعف محصول و برچسب "توصیه می‌کنم یا توصیه نمی‌کنم" برای

[40] Dense
[41] Dropout
[42] Learning Rate
[43] Epoch

هر نظر است. داده‌ها از وب سایت دیجی کالا[۴۴]، به‌عنوان یک بازارگاه اینترنتی، جمع‌آوری شده است. برای انجام عملیات پیش‌پردازش، از کتابخانه‌ی هضم[۴۵] استفاده شده است. هضم یک کتابخانه‌ی پایتون برای پردازش زبان طبیعی روی متن فارسی است. از هضم برای نرمال‌سازی متن، توکن‌سازی[۴۶]، یافتن ریشه کلمات[۴۷]، تحلیل نحوی و صرفی جملات و شناسایی وابستگی‌های دستوری استفاده می‌شود.

۴-۲- برچسب‌گذاری داده‌ها

برچسب‌گذاری داده‌های مورد استفاده در این پژوهش با دو روش انجام شده است. در روش اول، تعداد ۱۸۰۷ مورد از نظرهای کاربران به‌صورت دستی با توجه به جنبه‌های دوربین، باتری و قیمت در سه کلاس مثبت، منفی و خنثی برچسب‌گذاری شد. در جدول ۲، تعداد برچسب‌ها برای هر جنبه با روش برچسب‌گذاری دستی به تفکیک بیان‌شده است. به‌علت زمان‌بربودن برچسب‌گذاری داده‌ها به‌صورت دستی و همچنین تعداد کم داده‌های برچسب‌گذاری‌شده، جهت بهبود عملکرد رویکردهای پیشنهادی تصمیم گرفته شد که از یک روش برچسب‌گذاری خودکار استفاده شود. برچسب‌گذاری خودکار داده‌ها با توجه به نقاط قوت و ضعف مطرح‌شده توسط کاربر و کلمات کلیدی مرتبط با هر جنبه انجام شده است. بنابراین، هر یک از نقاط قوت و ضعف مطرح‌شده که مربوط به جنبه‌های مورد نظر است، با یک کلمه با بار احساسی مثبت یا منفی، جهت تکمیل مفهوم جمله، به متن اصلی نظر اضافه کرده و با توجه به آن برچسب‌گذاری شده است. با استفاده از این روش، تعداد ۴۳۷۳ نظر برچسب‌گذاری شده است. در شکل ۳ نمونه‌ای از روند برچسب‌گذاری خودکار داده‌ها نشان داده شده است. همچنین در جدول ۳ تعداد برچسب‌ها برای هر جنبه با روش برچسب‌گذاری خودکار به تفکیک بیان‌شده است.

۴-۳- مشخصات داده‌ها

پس از فرآیند برچسب‌گذاری، داده‌های نهایی در مجموع شامل ۶۱۸۰ نظر در مورد تلفن همراه است. داده‌ها در دسته‌بندی‌های دوربین، قیمت و باتری برچسب‌گذاری شده‌اند و تعداد برچسب‌های مربوط به هر دسته‌بندی در کلاس‌های مثبت، منفی و خنثی در جدول ۴ مطرح شده است. در این پژوهش از دو مجموعه داده، شامل داده‌های اولیه (با برچسب دستی) و داده‌های نهایی (ترکیب داده‌ها با برچسب‌های دستی و خودکار)، برای ارزیابی رویکردهای پیشنهادی استفاده شده است.

جدول ۲- تعداد برچسب‌ها برای هر جنبه با روش برچسب‌گذاری دستی

جنبه	مثبت	منفی	خنثی
دوربین	۳۴۰	۲۰۰	۱۲۶۷
باتری	۳۴۲	۱۱۷	۱۳۴۸
قیمت	۱۰۸۳	۱۳۵	۵۸۹

جدول ۳- تعداد برچسب‌ها برای هر جنبه با روش برچسب‌گذاری خودکار

جنبه	مثبت	منفی	خنثی
دوربین	۲۷۷۴	۱۱۸۴	۴۱۵
باتری	۳۱۶۸	۵۷۱	۶۳۴
قیمت	۱۳۲۳	۳۳۸	۲۷۱۲

شکل ۳- روش برچسب‌گذاری داده‌ها به‌صورت خودکار.

جدول ۴- تعداد برچسب های مثبت، منفی و خنثی در هر دسته‌بندی

دسته‌بندی	مثبت	منفی	خنثی
دوربین	۱۳۱۴	۱۳۸۴	۱۶۸۲
باتری	۳۵۱۰	۶۸۸	۱۹۸۲
قیمت	۲۴۰۶	۴۷۳	۳۳۰۱

۴-۳-۱- نرمال‌سازی

نرمال‌سازی با استفاده از کتابخانه‌ی هضم، برای پردازش زبان فارسی، به تغییرات رایج در خط فارسی مانند اشکال مختلف کاراکترها یا نشانه‌ها می‌پردازد. متن نرمال‌شده حاوی تغییراتی همچون اصلاح فاصله‌گذاری‌ها و نیم‌فاصله‌ها، حذف تکرارهای زائد حروف و تبدیل اعداد لاتین به اعداد فارسی است. برای مثال، جمله‌ی "دوربین این گوشی خیلیییی خوب است و نسبت به قیمت آن می‌ارزد"، پس از نرمال‌سازی به جمله‌ی "دوربین این گوشی خیلی خوب

[44] Https://www.digikala.com
[45] Hazm
[46] Tokenization
[47] Lemmatization

است و نسبت به قیمت آن می‌ارزد" تبدیل می‌شود.

۴-۳-۲- توکن‌سازی

کتابخانه‌ی هضم دارای تابعی به نام word tokenize است که به‌طور خاص، برای توکن‌سازی متن فارسی طراحی شده است. به این تابع متن ورودی داده می‌شود و خروجی آن لیستی از توکن‌های تشکیل‌دهنده متن است. به‌این‌ترتیب، از توکن‌های حاصل برای تحلیل و پردازش متن می‌توان استفاده کرد.

۴-۳-۳- افزایش داده‌ها

یکی از چالش‌ها در رویکردهای پردازش زبان طبیعی، کمبود داده‌های فارسی است. افزایش داده‌ها راهی برای مقابله با این چالش است. تصویر را می‌توان به راحتی با چرخاندن، استفاده از فیلترها و افزودن نویز افزایش داد؛ اما در زمینه کار با داده‌های متنی، با توجه به پیچیدگی زبان، افزایش داده‌ها دشوار است. در اینجا از روش‌های متوازن‌سازی و افزایش داده‌ها استفاده شده است. روش افزایش آسان داده‌ها[48] از چهار عملیات ساده ولی قدرتمند شامل جایگزینی مترادف[49]، درج تصادفی[50]، جابه‌جایی تصادفی[51] و حذف تصادفی[52] تشکیل شده است. برای استفاده از روش افزایش آسان داده‌ها از کتابخانه nlpaug بهره گرفته شده است. در جدول ۵ نتایج استفاده از هر کدام از این عملیات‌ها روی مدل زبانی برت بیان شده است. با توجه به نتایج به‌دست‌آمده، از روش جابه‌جایی تصادفی برای بقیه‌ی رویکردها استفاده شده است. در جدول ۶ تعداد داده‌ها پس از افزایش، با استفاده از عملیات جابه‌جایی تصادفی، روی داده‌های نهایی به تفکیک بیان شده است.

جدول ۵- نتایج افزایش داده‌ها روی مدل زبانی برت

عملیات	دوربین	باتری	قیمت
جایگزینی مترادف	۷۰/۵	۷۷/۴۳	۸۰/۱۰
درج تصادفی	۷۵/۲۰	۸۷/۷۷	۸۲/۶۱
جابه‌جایی تصادفی	۸۳/۱۲	۹۳/۸۸	۹۰/۳۲
حذف تصادفی	۷۲/۳۰	۸۳/۴۰	۷۹/۹۰

جدول ۶- تعداد برچسب‌ها پس از افزایش داده‌ها با روش جابه‌جایی تصادفی

جنبه	مثبت	منفی	خنثی	اولیه	تعداد نهایی پس از افزایش
دوربین	۳۱۱۴	۲۷۰۱	۳۳۴۸	۶۱۸۰	۹۱۶۳
باتری	۳۵۱۰	۳۲۸۰	۳۹۴۰	۶۱۸۰	۱۰۷۳۰
قیمت	۲۴۰۶	۳۲۰۳	۳۳۰۱	۶۱۸۰	۸۹۱۰

۴-۴- مشخصات سیستم

برای پیاده‌سازی رویکردهای پیشنهادی در این پژوهش از سرویس گوگل‌کولب استفاده شده است. در این پژوهش، سرویس مورد استفاده برای پیاده‌سازی دارای ۱۲ گیگابایت حافظه رم، ۱۰۰ گیگابایت فضای ذخیره‌سازی، دو پردازنده Intel Xeon و پردازنده گرافیکی NVIDIA Tesla است.

۴-۵- تحلیل و ارزیابی رویکردهای پیشنهادی

در این پژوهش برای پیاده‌سازی رویکردهای پیشنهادی، در تمام اجراها ازتابع هزینه Categorical Cross Entropy، Sparse مناسب برای مسائل چندکلاسه، بهینه‌ساز Adam و نرخ‌یادگیری ۰/۰۰۰۰۱ استفاده شده است. همچنین نسبت داده‌های آزمون و داده‌های ارزیابی ۰/۳ و مقدار k-fold، ۵ در نظر گرفته شده است. تعداد دوره‌ها نیز مقادیر ۱، ۵ و ۱۰ لحاظ شده است. در ادامه، معیارهای ارزیابی مورد استفاده در این پژوهش، جزییات مربوط به پیاده‌سازی هرکدام از رویکردها و نتایج حاصل از آن‌ها با داده‌های اولیه و نهایی بیان‌شده است.

۴-۵-۱- معیارهای ارزیابی

در این پژوهش برای ارزیابی عملکرد رویکردهای پیشنهادی از دو معیار ارزیابی صحت[53] و امتیاز F1[54] استفاده شده است. در روابط ۱ تا ۴ نحوه محاسبه این معیارها بیان‌شده است. در این روابط، TP تعداد نمونه‌هایی است که به درستی در کلاس مثبت و FP تعداد نمونه‌هایی است که اشتباه در کلاس مثبت تشخیص داده شده‌اند. همچنین TN تعداد نمونه‌هایی است که به درستی در کلاس منفی و FN تعداد نمونه‌هایی است که اشتباه در کلاس منفی تشخیص داده شده‌اند.

صحت: نشان‌دهنده درصد نمونه‌های صحیحی است که مدل تشخیص داده است. این معیار به‌عنوان نسبت تعداد پیش‌بینی‌های صحیح به تعداد کل پیش‌بینی‌ها ارائه می‌شود و به این معناست که مدل تا چه اندازه پیش‌بینی درست داشته است.

[48] Easy Data Augmentation (EDA)
[49] Synonym
[50] Random Insertion
[51] Random Swap
[52] Random Deletion
[53] Accuracy
[54] F1-Score

فراخوانی[55]: نسبت تعداد نمونه‌های درست تشخیص داده‌شده به تعداد کل نمونه‌های واقعی در یک کلاس را نشان می‌دهد.

دقت[56]: نسبت تعداد نمونه‌های واقعی که به درستی در یک کلاس مشخص تشخیص داده شده‌اند.

$$Accuracy= \frac{TP + TN}{TP} \quad (۱)$$

$$Recall= \frac{TP}{TP + FN} \quad (۲)$$

$$Precision= \frac{TP}{TP+FP} \quad (۳)$$

$$F1\text{-}Score=2*\frac{Precision*Recall}{Precision+Recall} \quad (۴)$$

۴-۵-۲- پیاده‌سازی و ارزیابی رویکرد شبکه عصبی پیچشی

برای پیاده‌سازی شبکه عصبی پیچشی برای طبقه‌بندی متن، از کتابخانه Keras و Tensorflow استفاده شده است. با بهره‌گیری از توابع فعال‌سازی Relu و Softmax و تنظیم ابرپارامترهای مربوط، مدل آموزش داده و ارزیابی شده است. در جدول ۷ مقادیر ابرپارامترهای مربوط به شبکه عصبی پیچشی آمده است.

جدول۷ - ابرپارامترهای شبکه عصبی پیچشی

پارامتر	مقدارهای آزمایش‌شده	مقدار بهینه انتخاب‌شده
سایز فیلتر	۳،۴،۵	۳
اندازه فیلتر	۳۲،۶۴،۱۲۸	۱۲۸
اندازه دسته	۶۴،۱۲۸،۲۵۶	۶۴
نرخ حذف تصادفی	۰/۳ ،۰/۵ ،۰/۷	۰/۵

در جدول ۸ نتایج رویکرد شبکه عصبی پیچشی روی داده‌های اولیه با ۱ دوره گزارش شده است. منظور از متوازن همان روش افزایش داده‌ها است که در صورت اعمال روی داده‌ها با "بله" و در صورت عدم اعمال روی داده‌ها با "خیر" مشخص شده است. نتایج حاصل نشان می‌دهد که به‌صورت کلی، رویکرد مورد نظر روی داده‌های افزایش‌یافته بهترین عملکرد را در هر سه جنبه داشته است.

جدول ۸- نتایج شبکه عصبی پیچشی روی داده‌های اولیه

جنبه	متوازن	صحت	امتیازF1
	خیر	۸۰/۷۱	۶۱/۶۶
دوربین	بله	۹۷/۸۳	۸۱/۷۹
باتری	خیر	۸۵/۶۷	۶۸/۱۵
	بله	۹۷/۴۶	۸۲/۷۵
قیمت	خیر	۹۳/۲۰	۶۶/۲۳
	بله	**۹۸**	**۸۱/۱۰**

در جدول ۹ نتایج رویکرد شبکه عصبی پیچشی روی داده‌های نهایی با ۵ و ۱۰ دوره گزارش شده است. نتایج حاصل نشان می‌دهد که در مجموع رویکرد شبکه عصبی پیچشی، روی داده‌های افزایش‌یافته با ۱۰ دوره بهترین عملکرد را در هر سه جنبه داشته است. بنابراین، می‌توان نتیجه گرفت که روش افزایش آسان داده‌ها با عملیات جابه‌جایی تصادفی، برای متوازن‌سازی داده‌ها، تأثیر مثبتی در عملکرد مدل داشته و باعث بهبود نتایج شده است.

جدول ۹- نتایج شبکه عصبی پیچشی روی داده‌های نهایی

دوره		۵		۱۰	
جنبه	متوازن	صحت	امتیازF1	صحت	امتیازF1
دوربین	خیر	۷/۵۸۸	۶۹/۹۲	۹۵/۹۰	۷۵/۴۲
	بله	۹/۸۲۲	۷۷/۴۱	۹۷/۹۲	۷۷/۴۵
باتری	خیر	۸/۴۵۱	۶۱/۴۵	۸۷/۰۹	۷۱/۳۱
	بله	۹/۸۵۳	۷۹/۹۹	۹۷/۴۳	۸۰/۱۷
قیمت	خیر	۸/۴۸۰	۸۴/۷۴	۹۵/۵۱	۸۰/۸۹
	بله	۹/۲۵۱	۷۸/۴۸	**۹/۶۶۸**	**۸۸/۹۴**

در شکل‌های ۴، ۵ و ۶ نمودار ارزیابی دقت و هزینه شبکه عصبی پیچشی برای هر سه جنبه روی داده‌های نهایی و متوازن‌شده نمایش داده شده است. همانطور که در هر سه نمودار ارزیابی دقت مشخص است، در طی دوره‌های ابتدایی، اختلاف بین دقت اعتبارسنجی و دقت آموزش نشان می‌دهد که بیش‌برازش رخ داده است. پس از سومین دوره، دقت اعتبارسنجی شروع به همگرایی با دقت آموزش می‌کند. این همگرایی نشان‌دهنده تثبیت آموزش مدل است و مدل به‌عنوان یک تعمیم‌دهنده به خوبی عمل کرده است.

[55] Recall

[56] Precision

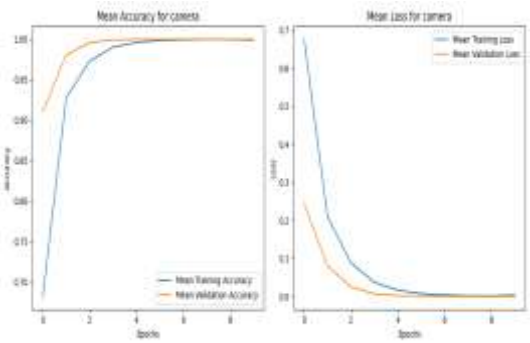

شکل ۴- نمودار ارزیابی دقت و هزینه شبکه عصبی پیچشی در دسته‌بندی دوربین روی داده‌های نهایی

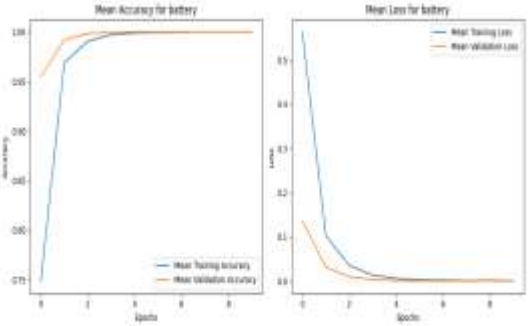

شکل ۵- نمودار ارزیابی دقت و هزینه شبکه عصبی پیچشی در دسته‌بندی باتری روی داده‌های نهایی

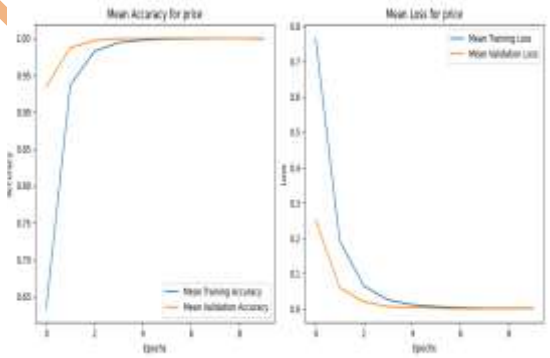

شکل ۶- نمودار ارزیابی دقت و هزینه شبکه عصبی پیچشی در دسته‌بندی قیمت روی داده‌های نهایی

۴-۵-۳- پیاده‌سازی و ارزیابی رویکرد برت

در رویکرد برت از مدلی ازپیش‌آموزش‌دیده روی نظرهای کاربران دیجی‌کالا، در بستر هاگینگ‌فیس[57] استفاده شده است. هاگینگ‌فیس بستری آموزشی برای پژوهش در زمینه پردازش زبان طبیعی است. برای استفاده از مدل برت از کتابخانه‌ی Transformers استفاده شده است. در جدول ۱۰ مقادیر ابرپارامترهای مربوط به مدل برت آمده است. در ادامه با استفاده از یک مدل برت ازپیش‌آموزش‌دیده برای زبان فارسی و مبتنی‌بر ترنسفورمر، داده‌های اولیه و نهایی روی مدل ارزیابی شده است. در جدول ۱۱ نتایج رویکرد برت روی داده‌های اولیه با ۵ دوره گزارش شده است. نتایج حاصل نشان می‌دهد که رویکرد برت، روی داده‌های افزایش‌یافته بهترین عملکرد را در هر سه جنبه داشته است. در جدول ۱۲ نتایج رویکرد برت روی داده‌های نهایی با ۱ و ۵ دوره گزارش شده است. نتایج حاصل از این رویکرد نیز نشان می‌دهد که در مجموع رویکرد برت، روی داده‌های افزایش‌یافته با ۵ دوره بهترین عملکرد را در هر سه جنبه داشته است. بنابراین، می‌توان نتیجه گرفت که روش افزایش آسان‌داده‌ها با عملیات جابه‌جایی تصادفی، برای متوازن‌سازی داده‌ها، تأثیر مثبتی روی عملکرد این مدل نیز داشته و باعث بهبود نتایج شده است.

جدول ۱۰- ابرپارامترهای مدل برت

ابرپارامتر	مقدارهای آزمایش‌شده	مقدار بهینه انتخاب‌شده
اندازه دسته	۶۴،۱۲۸،۲۵۶	۶۴
حداکثر طول ورودی[58]	۱۲۸،۲۵۶،۵۱۲	۲۵۶
نرخ حذف تصادفی	۰/۳ ،۰/۵ ،۰/۷	۰/۵

جدول ۱۱- نتایج مدل زبانی برت روی داده‌های اولیه

جنبه	متوازن	صحت	امتیاز F1
دوربین	خیر	۷۳/۴۸	۶۸/۷۸
	بله	۸۳/۱۲	۸۲/۹۶
باتری	خیر	۷۶/۱۱	۶۸/۴۵
	بله	**۹۳/۸۸**	**۹۳/۱۰**
قیمت	خیر	۷۷/۲۷	۷۴/۸۳
	بله	۹۰/۳۲	۹۰/۳۱

جدول ۱۲- نتایج مدل زبانی برت روی داده‌های نهایی

دوره		۱		۵	
جنبه	متوازن	صحت	امتیاز F1	صحت	امتیاز F1
دوربین	خیر	۸/۲۹۸	۸۸/۸۸	۸/۷۶۸	۸۹/۶۸
	بله	۹/۳۴۰	۹۰/۳۷	۹/۸۶۱	۹۳/۰۴
باتری	خیر	۹/۹۳۱	۹۱/۷۱	۹/۴۳۲	۹۲/۱۴

[57] Hugging Face

[58] Max Sequence Length

	بله	۹/۵۲۳	۹۳/۷۱	**۹۵/۱۱**	**۹۶/۳۶**
قیمت	خیر	۸/۸۵۹	۸۹/۱۸	۹/۱۳۰	۸۹/۲۰
	بله	۹/۵۵۰	۹۰/۸۶	۹/۷۷۲	۹۳/۴۶

۴-۵-۴- پیاده‌سازی و ارزیابی رویکرد فست‌تکست

برای پیاده‌سازی مدل فست‌تکست از کتابخانه FastText استفاده شده است. با تنظیم ابرپارامترهای مربوط، مدل روی داده‌ها آموزش داده و ارزیابی شده است. این فرآیند شامل ارتقاء وزن‌های مدل و تنظیم آن‌ها به گونه‌ای است که مدل، متن را به درستی دسته‌بندی کند. برای این منظور مقدار n-gram، ۲ و ۳ در نظر گرفته شده که مقدار ۳ نتایج بهتری به‌همراه داشته است. در جدول ۱۳ نتایج رویکرد فست‌تکست روی داده‌های نهایی با ۱ و ۵ دوره گزارش شده است. بر اساس نتایج، رویکرد فست‌تکست نیز همانند دو رویکرد دیگر، روی داده‌های افزایش‌یافته بهترین عملکرد را در هر سه جنبه داشته است. بنابراین، می‌توان نتیجه گرفت که روش افزایش‌آسان‌داده‌ها تأثیر مثبتی روی عملکرد این مدل نیز داشته و باعث بهبود نتایج شده است.

جدول ۱۳-نتایج مدل زبانی فست‌تکست روی داده‌های نهایی

دوره		۱		۵	
جنبه	متوازن	صحت	امتیاز F1	صحت	امتیاز F1
دوربین	خیر	۶/۳۴۹	۶۰/۷۳	۷/۷۸۲	۶۷/۷۰
	بله	۷/۶۱۸	۷۲/۱۷	۸/۶۷۲	۸۰/۴۲
باتری	خیر	۷/۲۳۰	۶۹/۵۰	۷/۶۳۵	۷۰/۷۷
	بله	۸/۶۳۲	۷۷/۹۷	۸/۷۹۵	۸۴/۳۰
قیمت	خیر	۷/۲۷۴	۷۲/۵۲	۷/۵۴۵	۷۳/۰۸
	بله	۸/۸۳۳	۷۶/۱۵	**۹/۱۳۰**	**۸۹/۳۰**

۴-۶- جمع بندی و مقایسه رویکردها

در این پژوهش، از سه رویکرد مختلف تحلیل احساسات و طبقه‌بندی متن از نظر احساسات مثبت، منفی و خنثی در سه جنبه‌ی دوربین، باتری و قیمت استفاده شد. همچنین با بررسی روش‌هایی برای متوازن‌سازی داده‌ها، تأثیر آن در نتایج هر رویکرد بررسی شد. مدل زبانی برت به‌عنوان یک معماری قدرتمند در پردازش زبان طبیعی شناخته شده است و در بسیاری از رویکردهای حوزه زبان طبیعی کارآمد است. به دلیل پیچیدگی معماری برت و تعداد بالای پارامترها، سرعت اجرای آن کمتر از روش‌های فست‌تکست و شبکه عصبی پیچشی است. بنابراین، آموزش و استفاده از مدل برت نیازمند زمان و منابع محاسباتی بیشتری است. در این پژوهش، با استفاده از رویکرد برت، بهترین نتایج را از نظر امتیاز F1 در هر سه جنبه داشت؛ با این حال زمان اجرا برای آموزش و ارزیابی در هر جنبه بیش از ۱۶۰ دقیقه شده است. شبکه عصبی پیچشی نیز به‌عنوان روشی قدرتمند در حوزه پردازش زبان طبیعی و کارهایی مانند تحلیل احساسات و دسته‌بندی متن مورد استفاده قرار می‌گیرد. معمولا این رویکرد، به دلیل ساختار ساده‌تر و تعداد کمتر پارامترها، سرعت اجرای بالاتری نسبت به رویکرد برت دارد. بنابراین، شبکه عصبی پیچشی در مقیاس بزرگتر و با داده‌های بیشتر، می‌تواند سریع‌تر اجرا شود. در این پژوهش، با استفاده از این رویکرد، از نظر معیار صحت، به بهترین نتایج در هر سه جنبه دست یافتیم. زمان اجرا برای آموزش و ارزیابی برای هر جنبه نیز در بازه زمانی ۱۰۰ الی ۱۲۰ دقیقه قرار گرفته که نسبت به مدل برت زمان مطلوب‌تری برای رسیدن به خروجی است. مدل زبانی فست‌تکست روشی سبک برای پردازش زبان طبیعی است و برای کارهایی مانند بردارسازی کلمات، تحلیل احساسات و طبقه‌بندی متن استفاده می‌شود. این روش با داده‌های با حجم زیاد به خوبی کار می‌کند و نتایج قابل قبولی را با سرعت بالا ارائه می‌دهد. در این پژوهش، با استفاده از این رویکرد نیز نتایج خوبی در هر سه جنبه به‌دست آمد. مزیت استفاده از این روش، زمان اجرای بسیار کم آن است و زمان اجرا برای آموزش و ارزیابی برای هر جنبه کمتر از ۱۰ ثانیه شده است که نسبت به دو رویکرد قبلی، زمان بسیار خوبی برای رسیدن به خروجی است. مدل‌های شبکه عصبی پیچشی، برت و فست‌تکست در بهترین حالت به ترتیب مقادیر ۹۸/۹۴، ۹۶/۳۶ و ۸۹/۳۰ درصد را با معیار امتیاز F1 کسب کردند.

۵- نتیجه‌گیری و پیشنهادها

مردم در سراسر جهان، نظرهای خود را در مورد موضوعات

مختلفی همچون فیلم‌ها، محصولات، سیاست و مسائل روز دنیا در بسترهای اینترنتی و رسانه‌های اجتماعی به اشتراک می گذارند. تحلیل احساسات برای طبقه‌بندی خودکار این احساسات به‌عنوان احساس مثبت، منفی و یا خنثی استفاده می‌شود. در زمینه تحلیل احساسات تاکنون تحقیقات زیادی روی داده‌های انگلیسی انجام شده؛ اما برای زبان فارسی کارهای کمتری صورت گرفته است. در این پژوهش تلاش شد تا با به‌کارگیری روش‌های مناسب برای پیش‌پردازش داده‌های فارسی و استفاده از رویکردهای شبکه عصبی پیچشی و مدل‌های زبانی برت و فست‌تکست، تحلیل احساسات نظرهای کاربران در مورد تلفن همراه در جنبه‌های دوربین، باتری و قیمت در وب‌سایت دیجی‌کالا انجام شود. تحلیل احساسات با توجه به جنبه‌های مختلف به ما کمک می‌کند تا تحلیل دقیق‌تری از نظرهای کاربران و همچنین درک بهتری از نیازهای مشتریان داشته باشیم. علاوه‌براین، منجر به شناخت جنبه‌های گوناگون از یک تلفن همراه مانند کیفیت دوربین، عمر باتری و قیمت آن می‌شود. در همین راستا، داده‌ها مبتنی‌بر جنبه و بر اساس سه احساس مثبت، منفی و خنثی برچسب‌گذاری شد. این پژوهش برای درک بهتر عقاید و نظرهای کاربران و همچنین استفاده از این داده‌ها برای پیش‌بینی نظرهای مثبت، منفی و خنثی انجام شده است. برای ارزیابی عملکرد رویکردهای پیشنهادی، از دو مجموعه داده شامل داده‌های اولیه با برچسب‌گذاری دستی و داده‌های نهایی با ترکیب داده‌ها با برچسب‌گذاری دستی و خودکار استفاده شده است. یکی از چالش‌های موجود در این پژوهش، عدم توازن بین داده‌ها در کلاس‌های مثبت، منفی و خنثی بوده است. به همین منظور، برای متوازن‌سازی جنبه‌ها در هر دسته‌بندی، از روش‌های افزایش داده نیز روی داده‌های نهایی بهره گرفته شده است. در نهایت با استفاده از مدل‌های پیشنهادی، دقت بسیار بالایی در تشخیص نظرهای مثبت، منفی و خنثی در هر جنبه به‌دست آمد. این نتایج حاکی از آن است که مدل‌های مورد نظر در پیش‌بینی احساسات نظرهای به‌خوبی عمل کرده‌اند. همچنین نتایج نشان می‌دهد که شبکه عصبی پیچشی، از نظر معیار صحت، عملکرد بهتری نسبت به رویکردهای دیگر داشته است. از نتایج به‌دست‌آمده در این پژوهش می‌توان در حوزه‌های مختلف از جمله بازاریابی، خدمات مشتریان و توسعه محصولات بهره برد.

۶- کار آینده

به دلیل محدودیت در دسترسی به مجموعه داده‌های متنوع، در آینده با فراهم‌شدن مجموعه داده‌های بیشتر، مقایسه مدل‌ها روی دامنه‌های متنوع‌تر انجام خواهد شد. همچنین می‌توان با افزودن لایه‌های عمیق‌تر به شبکه‌های پیچشی به دقت بیشتری در تشخیص احساسات دست پیدا کرد. همچنین می‌توان با استفاده از داده‌های بیشتر و در نظرگرفتن جنبه‌های بیشتر، به استخراج برخی از جنبه‌های کیفی و تمرکز روی یک سری کالاهای خاص پرداخت و تأثیر پارامترهایی همچون گذر زمان و نوع کالا را در رویکردهای تحلیل احساسات بررسی کرد. با تحلیل احساسات نظرها و بازخوردهای کاربران و درک بهتر از نیازها و خواسته‌های آن‌ها، می‌توان به‌صورت شخصی‌سازی‌شده پیشنهادهایی را برای آن‌ها ارائه داد. به‌عنوان مثال، با توجه به نتایج تحلیل احساسات مشتریان، می‌توان محصولات مرتبط را برای جلب رضایت آن‌ها پیشنهاد کرد.

تاییدیه اخلاقی

نویسندگان متعهد می‌شوند که مطالب این مقاله را در هیچ مجله دیگری به چاپ نرسانده اند.

تعارض منافع

نویسندگان اعلام می‌کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

مراجع

[1] L. Yue, W. Chen, X. Li, W. Zuo, and M. Yin. "A survey of sentiment analysis in social media." *Knowledge and Information Systems* 60 (2019): 617-663.

[2] Z. Rajabi, and M. R. Valavi. "A survey on sentiment analysis in Persian: a comprehensive system perspective covering challenges and advances in resources and methods." *Cognitive Computation* 13, no. 4 (2021): 882-902.

[3] R. Asgarnezhad, and S.A. Monadjemi. "Persian sentiment analysis: feature engineering, datasets, and challenges." *Journal of applied intelligent systems & information sciences* 2, no. 2 (2021): 1-21.

[4] M. Shamsfard. "Challenges and opportunities in processing low resource languages: A study on persian." In *International Conference Language Technologies for All (LT4All)*. 2019.

[5] M. Birjali, M. Kasri, and A. Beni-Hssane. "A comprehensive survey on sentiment analysis: Approaches, challenges and trends." *Knowledge-Based Systems* 226 (2021): 107134.

[6] J. K. Rout, et al. "A model for sentiment and emotion analysis of unstructured social media text." *Electronic Commerce Research* 18 (2018): 181-199.

[7] S. Behdenna, F. Barigou, and G. Belalem. "Sentiment analysis at document level." In *Smart Trends in Information Technology and Computer Communications: First International Conference, SmartCom 2016, Jaipur, India, August 6–7, 2016, Revised Selected Papers 1*, p. 159-168. Springer Singapore, 2016.

[8] A. Yadav, Ashima, and D. K. Vishwakarma. "Sentiment analysis using deep learning architectures: a review." *Artificial Intelligence Review* 53, no. 6 (2020): 4335-4385.

[9] T. Chen, R. Xu, Y. He, and X. Wang. "Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN." *Expert Systems with Applications* 72 (2017): 221-230.

[10] HH. Do, P.W. Prasad, A. Maag, and A. Alsadoon. "Deep learning for aspect-based sentiment analysis: a comparative review." *Expert systems with applications* 118 (2019): 272-299.

[11] M. Wankhade, ACS. Rao, and C. Kulkarni. "A survey on sentiment analysis methods, applications, and challenges." *Artificial Intelligence Review* 55, no. 7 (2022): 5731-5780.

[12] M. Taboada, J. Brooke, M. Tofiloski, K. Voll, and M. Stede. "Lexicon-based methods for sentiment analysis." *Computational linguistics* 37, no. 2 (2011): 267-307.

[13] V. Bonta, N. Kumaresh, and N. Janardhan. "A comprehensive study on lexicon based approaches for sentiment analysis." *Asian Journal of Computer Science and Technology* 8, no. S2 (2019): 1-6.

[14] Q. Ye, Qiang, Z. Zhang, and R. Law. "Sentiment classification of online reviews to travel destinations by supervised machine learning approaches." *Expert systems with applications* 36, no. 3 (2009): 6527-6535.

[15] G. Paltoglou, and M. Thelwall. "Twitter, myspace, digg: Unsupervised sentiment analysis in social media." *ACM Transactions on Intelligent Systems and Technology (TIST)* 3, no. 4 (2012): 1-19.

[16] I. Gupta, and N Joshi. "Enhanced twitter sentiment analysis using hybrid approach and by accounting local contextual semantic." *Journal of intelligent systems* 29, no. 1 (2019): 1611-1625.

[17] K. Dashtipour, et al. "Exploiting deep learning for Persian sentiment analysis." In *Advances in Brain Inspired Cognitive Systems: 9th International Conference, Xi'an, China*, p. 597-604. Springer International Publishing, 2018.

[18] L. Zhang, S. Wang, and B. Liu. "Deep learning for sentiment analysis: A survey." *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 8, no. 4 (2018): e1253.

[19] X. Ouyang, P. Zhou, CH. Li, and L. Liu. "Sentiment analysis using convolutional neural network." In *2015 IEEE international conference on computer and information technology; ubiquitous computing and communications; dependable, autonomic and secure computing; pervasive intelligence and computing*, p. 2359-2364. IEEE, 2015.

[20] H. Gu, Y. Wang, S. Hong, and G. Gui. "Blind channel identification aided generalized automatic modulation recognition based on deep learning." *IEEE Access* 7 (2019): 110722-110729.

[21] J. Hassannataj Joloudari, et al. "BERT-deep CNN: State of the art for sentiment analysis of COVID-19 tweets." *Social Network Analysis and Mining* 13, no. 1 (2023): 99.

[22] A. Radford, K. Narasimhan, T. Salimans, and I. Sutskever. "Improving language understanding by generative pre-training." (2018).

[23] M. Farahani, M. Gharachorloo, M. Farahani, and M. Manthouri. "Parsbert: Transformer-based model for persian language understanding." *Neural Processing Letters* 53 (2021): 3831-3847.

[24] E. Grave, P. Bojanowski, P. Gupta, A. Joulin, and T. Mikolov. "Learning word vectors for 157 languages." *arXiv preprint arXiv:1802.06893* (2018).

[25] J. Devlin, MW. Chang, K. Lee, and K. Toutanova. "Bert: Pre-training of deep bidirectional transformers for language understanding." *In Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language technologies*, volume 1 (long and short papers), p. 4171-4186. 2019.

[26] Y. Cao, Z. Sun, L. Li, and W. Mo. "A study of sentiment analysis algorithms for agricultural product reviews based on improved BERT model." *Symmetry* 14, no. 8 (2022): 1604.

[27] R. Catelli, S. Pelosi, and M. Esposito. "Lexicon-based vs. Bert-based sentiment analysis: A comparative study in Italian." *Electronics* 11, no. 3 (2022): 374.

[28] A. Joulin, E. Grave, P. Bojanowski, and T. Mikolov. "Bag of tricks for efficient text classification." *arXiv preprint arXiv:1607.01759* (2016).

[29] A. Amalia, OS Sitompul, EB Nababan, and T. Mantoro. "An efficient text classification using fasttext for bahasa indonesia documents classification." In *2020 International Conference on Data Science, Artificial Intelligence, and Business Analytics*, p. 69-75. IEEE, 2020.

[30] MR. Hossain, MH. MM. Hoque, and IH. Sarker. "Text classification using convolution neural networks with fasttext embedding." In *International Conference on Hybrid Intelligent Systems*, p. 103-113. Cham: Springer International Publishing, 2020.

[31] T. Szandała. "Review and comparison of commonly used activation functions for deep neural networks." *Bio-inspired neurocomputing* (2021): 203-224.

[32] A. Jurek, MD. Mulvenna, and Y. Bi. "Improved lexicon-based sentiment analysis for social media analytics." *Security Informatics* 4 (2015): 1-13.

[33] Z. Singla, S. Randhawa, and S. Jain. "Sentiment analysis of customer product reviews using machine learning." In *2017 international conference on intelligent computing and control*, p. 1-5. IEEE, 2017.

[34] F. Ebrahimi Rashed, and N. Abdolvand. "A supervised method for constructing sentiment lexicon in persian language." *Journal of Computer & Robotics* 10, no. 1 (2017).

[35] Y. Al Amrani, M. Lazaar, and K. E. El Kadiri. "Random forest and support vector machine based hybrid approach to sentiment analysis." *Procedia Computer Science* 127 (2018): 511-520.

[36] H. Kim, and YS. Jeong. "Sentiment Classification Using Convolutional Neural Networks" *Applied Sciences* 9, no. 11 (2019): 2347. https://doi.org/10.3390/app9112347

[37] S. Soni, SS. Chouhan, and SS. Rathore. "TextConvoNet: A convolutional neural network based architecture for text classification." *Applied Intelligence* 53, no. 11 (2023): 14249-14268.

[38] B. Jang, M. Kim, G. Harerimana, S. Kang, and JW. Kim. "Bi-LSTM model to increase accuracy in text classification: Combining Word2vec CNN and attention mechanism." *Applied Sciences* 10, no. 17 (2020): 5841.

[39] W. Zhang, X. Li, Y. Deng, L. Bing, and W. Lam. "A survey on aspect-based sentiment analysis: Tasks, methods, and challenges." *IEEE Transactions on Knowledge and Data Engineering* 35, no. 11 (2022): 11019-11038.

[40] A. Omar, N. Siyam, A. Abdel Monem, and K. Shaalan. "Aspect-based sentiment analysis using smart government review data." *Applied Computing and Informatics* 20, no. 1/2 (2024): 142-161.

[41] N. Majumder, R. Bhardwaj, S. Poria et al. "Improving aspect-level sentiment analysis with aspect extraction." *Neural Computing and Applications* (2022): 1-11.

[42] D. Tang, B. Qin, X. Feng, and T. Liu. "Effective LSTMs for target-dependent sentiment classification." *arXiv preprint arXiv:1512.01100* (2015).

[43] M. Roustaei, and M. A. Javadzadeh. "Sentiment Analysis of Persian Language Users Based on the Combination of Semantic Relations and Random Forest." *In Proceedings of the 8th National Conference on Modern Studies and Researches in Computer Science, Electrical, and Mechanical Engineering of Iran, Tehran*, 2022. (in Persian)

[44] M. Ghasempour Marzbali, "Aspect-Based Sentiment Analysis Using BERT." *In Proceedings of the 4th International Conference on Artificial Intelligence and Its Future Perspective in Electrical, Computer, Mechanical, and Telecommunication Engineering, Mashhad*, 2024. (in Persian)

[45] F. Foroutan, and M. Rabiei. "Applying Deep Learning to Improve Sentiment Analysis Results of Persian Reviews in Online Retail Stores." *Iranian Journal of Information and Communication Technology* 57, no. 15 (2023): 122–137. (in Persian)

[46] B. Li, X. Liu, and R. Zhang. "Employing the BERT model for sentiment analysis of online commentary." *Applied and Computational Engineering* 32 (2024): 241-247.

[47] A. S. Talaat. "Sentiment analysis classification system using hybrid BERT models." *Journal of Big Data* 10, no. 1 (2023): 110.

[48] D. Manuel-Ilie, P. A. Gabriel, and R. G. Crețulescu. "Sentiment Analysis Using Bert Model." *International Journal of Advanced Statistics and IT&C for Economics and Life Sciences* 13, no. 1 (2023): 59-66.