

یادگیری عمیق در تحلیل احساسات کاربران شبکه های هوشمند سرمایه گذاری

نسرین صالحی چگنی^۱، صبا جودکی^{۲*}، مجتبی صالحی^۳

*تویسندۀ مسئول: دریافت: 1403/7/16 ، بازنگری: 1403/9/20 ، پذیرش: 1403/11/19

^۱گروه مهندسی کامپیوتر، واحد خرم آباد، دانشگاه آزاد اسلامی، خرم آباد، ایران

(saba.joudaki@iau.ac.ir)^۲گروه مهندسی کامپیوتر، واحد خرم آباد، دانشگاه آزاد اسلامی، خرم آباد، ایران

^۳گروه مهندسی کامپیوتر، واحد خرم آباد، دانشگاه آزاد اسلامی، خرم آباد، ایران

چکیده

تحلیل داده های سهام شرکت ها یکی از روش های مهم برای ارزیابی عملکرد و ارزش شرکت ها و انتخاب بهترین گزینه برای سرمایه گذاری در بازارهای مالی است. در این مقاله، مجموعه داده نظرات کاربران شبکه هوشمند سرمایه گذاری سهام یا ب با هدف تحلیل احساسات کاربران گردآوری شده است. ابتدا الگوریتم های درخت تصمیم، ماشین بردار پشتیبان، بیزین ساده و نزدیکترین همسایه پیاده سازی شدند؛ که بردار پشتیبان با صحت ۶۱ درصد بهترین عملکرد را به دست آورد. سپس برای مقایسه این الگوریتم های یادگیری عمیق، شبکه های LSTM و BERT به زبان فارسی و BERT به زبان انگلیسی پیاده سازی شدند. این مدل ها به ترتیب با صحت های ۷۲، ۸۲ و ۸۳ درصد عملکرد بهتری نسبت به الگوریتم های سنتی داشتند. در ادامه مدل LSTM با استفاده از الگوریتم فرا ابتكاری ژنتیک با هدف به دست آوردن هایپر بارامترهای بهینه پیاده سازی شد که به صحتی برابر با ۸۱/۴۶ درصد رسید. در فاز پایانی، الگوریتم BERT دو زبانه با ترکیب متن فارسی نظرات و معنای انگلیسی آنها پیاده سازی شد و به عملکرد ۸۴ درصد دست یافت. انتظار می رود استفاده از این مدل بتواند به بهبود عملکرد سیستم های پیش بینی کننده و توصیه گر در سایت های اقتصادی کمک نماید.

کلمات کلیدی: پردازش زبان طبیعی، تحلیل احساسات، یادگیری عمیق، شبکه عصبی، سیستم های توصیه گر

۱ - مقدمه

از سویی دیگر، روش های سنتی در نادیده گرفتن اطلاعات معنایی مندرج در متن محدودیت دارند. یکی دیگر از مسایل مطرح در روش های سنتی یادگیری ماشین مبحث مهندسی ویژگی است که دارای روالی طولانی و سخت است. برای حل این مشکلات و دستیابی به نتایج بهینه، استفاده از روش های یادگیری عمیق (Deep Learning) نسبت به روش های سنتی یادگیری ماشین از اولویت بالاتری برخوردار می باشد. یادگیری عمیق شاخه ای از یادگیری ماشین است. به عبارت دیگر همان یادگیری به وسیله شبکه های عصبی است که لایه های مخفی (Hidden Layers) زیادی دارد. روش های یادگیری ماشین در دو دسته اصلی با ناظر در صورت وجود برچسب و بدون ناظر در حالت بدون برچسب تقسیم می شوند که بیشتر کارهای انجام شده در سطح تحلیل متن مبتنی بر روش های با ناظر می باشند. بازار مالی به عنوان یک سیستم پیچیده با نوسانات غیرخطی از جمله بخش هایی است که از مزایای الگوریتم های متن کاوی بهره برده است. به عنوان مثال، متن کاوی در زمینه های مختلفی مانند درک و مدیریت ریسک مالی، مدیریت تسهیلات، رتبه بندی اعتباری مشتریان، تجزیه و تحلیل و رتبه بندی مشتریان بانکی، پیش

تجزیه و تحلیل احساسات یا نظر کاوی یک حوزه در حال پیشرفت است که به استفاده از پردازش زبان طبیعی، تجزیه و تحلیل متن اشاره دارد و برای استخراج کمیت مورد استفاده قرار می گیرد و برای مطالعه حالات احساسی از یک بخش مشخص از اطلاعات یا مجموعه داده های متنی مورد استفاده قرار می گیرد. تحلیل احساسات در بسیاری از شرکت ها برای بررسی محصولات، نظرات رسانه های اجتماعی و برای بررسی مثبت، منفی یا خنثی بودن متن استفاده می شود. بیشتر مطالعات در زمینه تحلیل احساسات در زبان انگلیسی از روش های یادگیری ماشین (Machine Learning) سنتی مانند Naïve Bayes درخت تصمیم گیری و استفاده n-gram می کنند. این روش ها معمولاً از ویژگی های n-gram و لغوی بهره می برند. در زبان شناسی مفهوم n-gram به معنای دنباله ای پیوسته از n جزء در یک دنباله معین از متون است. این اجزا می توانند حروف، واژه های را باشند.

ویژگی های محلی مقاوم در برابر موقعیت، ABCDM از مکانیزم های کانولوشن و ادغام استفاده می کند. اثربخشی ABCDM بر تشخیص قطبیت احساسی که رایج ترین و اساسی ترین وظیفه تحلیل احساسی است، ارزیابی می شود. آزمایش ها در پنج بررسی DNN و سه مجموعه داده توییتر انجام شده است. نتایج مقایسه ABCDM با شش ABCDM که اخیرا برای تجزیه و تحلیل احساسی پیشنهاد شده اند نشان می دهد که ABCDM به نتایج بسیار خوبی در بررسی بلند مدت و طبقه بندی قطبیت کوتاه توییت دست می یابد.

دشتی پور و همکاران [۴] یک مجموعه داده چند وجهی فارسی شامل بیش از ۸۰۰ جمله را به عنوان یک منبع معیار برای محققان به منظور ارزیابی رویکردهای تحلیل احساسات چند وجهی در زبان فارسی ارائه دادند. یک چارچوب جدید تحلیل احساسات چند وجهی آگاه از زمینه را که به طور همزمان از نشانه های صوتی، بصری و متنی برای تعیین دقیق تر احساسات بیان شده بهره می برد. از هر دو روش ترکیب سطح تصمیم (دیرهنگام) و سطح ویژگی (زود هنگام) برای ادغام اطلاعات موثر متقابل استفاده کردند. نتایج تحریب نشان می دهند که ادغام بافتی ویژگی های چند وجهی مانند ویژگی های متنی، صوتی و بصری عملکرد بهتری (۹۱.۳۹٪) را در مقایسه با ویژگی های تک وجهی (۸۹.۲۴٪) ارائه می دهند.

آک و همکاران [۵] از اخبار مالی برای پیش بینی عملکرد بازار سهام استفاده کردند. هنگ [۶] یک سیستم پیش بینی را براساس روش متن کاوی و اخبار بازار سهام پیشنهاد کرد. برای پاسخ به تغییرات بازار سهام در زمان واقعی، از LSTM استفاده کرد و براساس داده های تحلیل سری زمانی گذشته، نزدیک ترین وضعیت به زمانی را یافت که قیمت سهام با محاسبات ریاضی افزایش یافتد.

لی و همکاران [۷] نظر را با احساسات بسیار منفی / مثبت منتشر شده در وب سایتها های همسایه به عنوان یک نمونه انتخاب کردند و هنگام تست و مقایسه کارایی تحقیق رفتار کاربر، از تحلیل احساسی مختلف، تکنیک های یادگیری ماشین و تحلیل احساسی متنی بر فرهنگ لغت استفاده کردند و دریافتند که ترکیب یادگیری ماشین و روش مبنی بر واژگان می تواند بدقت بالاتری نسبت به هر نوع تحلیل احساسی دست یابد.

در تحقیقی دیگر با ایجاد سیستم های جدید تحلیل گر احساسات بر مبنای تکنیک های مختلفی از شبکه عصبی عمیق، دقت پیش بینی سهام بورس را بهبود داده شد تا سرمایه گذاران بورس بتوانند با آگاهی بهتر از روند تغییرات بورس، بازده سهام خود را افزایش دهند [۸-۹].

لوتز و همکاران [۱۰] یک رویکرد یادگیری ماشینی جدید را برای پیش بینی بر چسب های قطبیت سطح جمله در اخبار مالی توسعه دادند. روش آن ها از نمایش متن توزیع شده و یادگیری چند نمونه ای برای انتقال اطلاعات از سطح سند به سطح جمله استفاده کرد. سیستم خبره پیشنهادی می تواند به سرمایه گذاران در تصمیم گیری خود کمک کند و ممکن است به آن ها در برقراری ارتباط با پیام های مورد نظر کمک کند.

روییمن و همکاران [۱۱] یک الگوریتم تجزیه و تحلیل احساسی متن چینی را بر اساس BERT و CNN پیشنهاد می کنند. این شبکه از "BERT" برای استخراج ویژگی های هر کلمه و استفاده از آن به عنوان ورودی سی ان ان استفاده می کند. آزمایش ها نشان می دهند که این مدل از نظر اثربخشی امکان پذیر است. مدل BERT ساختار ترانسفورمر Decoder - Encoder را براساس چارچوب ترانسفورمر پیاده سازی می کند. ساختار ترانسفورمر در ترانسفورماتور هم چنین از چارچوب - Encoder استفاده می کند که مازول رمزگذار آن از ۶ رمزگذار و مازول رمزگشا از ۶ رمزگشا تشکیل شده است. هر کدگذار شامل یک لایه خود - توجیهی و یک شبکه عصبی پیش خور است. توجه به خود به گره فعلی اجازه می دهد تا نه تنها بر روی کلمه فعلی تمرکز کند، بلکه معانی متن را نیز درک کند. هر گره Decoder شامل یک لایه خود - توجیهی، یک لایه توجه و یک شبکه عصبی پیش خور است. لایه

بینی سود سهام، پیش بینی بازار بورس، پیش بینی نرخ ارز، پیش بینی ورشکستگی باانک ها، تحلیل احساسات سرمایه گذاران، تحلیل نظرات مشتریان و تشخیص کلاه برداران مالی به این قدر پراخته است. عموماً سرمایه گذاران بازار مالی به منظور سود بیشتر، نظرات و حالت های احساسی خود را با دیگر سرمایه گذاران به اشتراک می گذارند و در نتیجه رفتار سرمایه گذاران مالی بر قیمت های بازار سهام تأثیرگذار خواهد بود. ولی از آن جایی که غالب سرمایه گذاران از روند تغییرات بازارهای مالی اطلاع ندارند، بررسی حالت های احساسی سرمایه گذاران و شناسایی الگوهای مخفی بین نظرات مردم در رسانه های اجتماعی، می تواند آن ها را برای رسیدن به سودآوری بیشتر، شناخت تغییرات بازار و پیشگویی حوادث اقتصادی یاری کند. امروزه محققان در صدد هستند تا با به کار گیری تکنیک های هوش مصنوعی مانند شبکه های عصبی پیچشی و یا سایر نمونه های شبکه های عصبی عمیق به ارزیابی نظرات، تحلیل داده های احساسی مشتریان یا کاربران در فضاهای مجازی و نیز شناسایی و پیش بینی تغییرات در بازار بپردازند. سیستم های هوشمند تحلیل گر احساسات، نقش مهمی را در تحلیل و طبقه بندی نظرات، توصیف ها و نگرش های مردم نسبت به موضوعات مطرح در کامنت های شبکه های اجتماعی بازی می کنند.

هدف این مقاله ارائه یک مدل مبتنی بر شبکه عصبی عمیق به منظور تحلیل نظرات کاربران سایت سهامیاب و مقایسه دقت و کارایی مدل پیشنهادی با مدل های سنتی یادگیری ماشین است. برای این منظور، نظرات کاربران سایت سهامیاب در خصوص بورس تهران جمع آوری شد. سپس بار معنایی جملات با استفاده از تکنیک های متن کاوی و آنالیز احساسات تعیین گردید و با استفاده از الگوریتم های یادگیری ماشینی به دسته های مثبت و منفی طبقه بندی شد به این شکل که نظرات مثبت با عدد ۱ و نظرات منفی با عدد صفر بر جسب گذاری شدند.

از آن جا که متن، داده های بدون ساختار است، پیش پردازش برای تبدیل این داده های بدون ساختار به فرم ساختار یافته مورد نیاز است. سپس با انجام فرآیند یادگیری با استفاده از داده های مجموعه آموزشی (Train) الگوریتم های ماشین یادگیر پیاده سازی شده و مدل یادگیری ماشین ساخته می شود و در نهایت با استفاده از داده های آزمایشی (Test) ارزیابی می شود. در حالت کلی مراحل طراحی و پیاده سازی به صورت جمع آوری مجموعه داده، بر چسب گذاری داده ها، پیش پردازش داده، تشکیل بردار کلمه، اجرای الگوریتم های سنتی یادگیری ماشین، طراحی شبکه عمیق، اجرای الگوریتم ژنتیک، ارزیابی کلی نتایج و ارائه مدل نهایی بیان می شود.

۲ - مطالعات انجام شده

بستان و همکاران [۱] درون سازی واژگان فارسی با استفاده از الگوریتم BERT را مورد بررسی قرار دادند و به درک معنایی هر واژه بر مبنای بافت متن پرداختند. مدل ایجاد شده بر روی مجموعه دادگان وب فارسی مورد پیش آموزش قرار گرفت و پس از طی دو مرحله تنظیم دقیق با معماري های متفاوت، مدل نهایی تولید شد. نتایج حاصل از این مدل بهبود خوبی نسبت به سایر مدل های مورد بررسی داشت و دقت را نسبت به مدل BERT چند زبانه تاحدا قابل یک درصد افزایش داد.

انتونا کاکی و همکاران [۲] موضوعات تحقیقاتی فعلی را در توییتر با تمرکز بر سه حوزه اصلی ترسیم کردند: ساختار و ویژگی های نمودار اجتماعی، تحلیل احساسی و تهدیدهایی مانند اسپم، ربات ها، اخبار جعلی و سخنان نفرت آمیز. همچنین مدل داده پایه توییتر و بهترین روش ها برای نمونه گیری و دسترسی به داده را ارائه دادند و زمینه تکنیک های محاسباتی مورد استفاده در این حوزه ها مانند نمونه برداری گراف، پردازش زبان طبیعی و یادگیری ماشینی را ارائه دادند.

بصیری و همکاران [۳] اولین مدل عمیق دو جهتی CNN - RNN مبتنی بر توجه را برای تحلیل احساسی پیشنهاد کردند. مدل آن ها هم در طبقه بندی طولانی و هم در طبقه بندی کوتاه قطبیت توییت به نتایج سطح بالا دست یافت. هم چنین، مکانیزم توجه بر روی خروجی های لایه های دو طرفه ABCDM برای تأکید پیش تر یا کمتر بر روی کلمات مختلف اعمال می شود. برای کاهش ابعاد ویژگی ها و استخراج

جدول ۱ - نمای کلی مجموعه داده			
Table	Review_text	Username	Stock_name
۱۰۰	متن نظرات	نام کاربری	نام سهام

۳-۲- برچسب‌گذاری مجموعه داده‌ها

برچسب‌گذاری مجموعه داده فرآیندی در یادگیری ماشینی است که در آن داده‌های خام مانند تصاویر، فایل‌های متند، ویدئوها و غیره را می‌توان شناسایی کرد و برای ارائه زمینه‌ای که اجازه می‌دهد یک یا چند برچسب معنی‌دار و آموزنده را اضافه کرد، استفاده می‌شود. به طوری که مدل یادگیری ماشینی بتواند چیزی از آن بیاموزد؛ هم‌چنین اجازه می‌دهد تا یک مجموعه داده را در یادگیری ماشینی برچسب‌گذاری کنید و در یادگیری نظارت شده، برچسب‌گذاری مجموعه داده، بخش مهمی از پیش‌پردازش داده است؛ بنابراین برای طبقه‌بندی می‌تواند ورودی و خروجی را برچسب‌گذاری کند. برچسب‌گذاری داده‌ها فرآیند مهمی است؛ زیرا می‌تواند قبل از استفاده از آن در مدل آموزشی، زمینه و مفهوم را به داده‌ها اضافه کند، به طوری که برچسب‌گذاری داده‌ها به ما کمک می‌کند تا زمانی که می‌خواهیم عامل مقیاس‌بندیری و فاکتور کیفیت را بهبود بخشیم، رویکرد صحیح را انتخاب کنیم. برچسب‌گذاری داده‌ها فرآیند شناسایی داده‌های خام و برچسب‌گذاری آن است، به همین منظور در این پژوهش با استفاده از نظرخواهی از چندین نفر برچسب‌گذاری نظرات به دو صورت مثبت و منفی (۱۰+) انجام شده است. این مجموعه داده دارای ۱۰۲۴ نمونه از نظرات کاربران سایت سهامیاب می‌باشد که هر کدام از این برچسب‌ها قطبیت نظرات در مورد شرکت‌های فعال بورس را بیان می‌کند.

۳-۳- پیش‌پردازش داده

باتوجه به اینکه داده‌هایی که در این مقاله استفاده شده است از ستر اینترنت جمع‌آوری شده‌اند، ساختار مناسبی برای ورود به شبکه‌های عصبی عمیق ندارند، بنابراین قبل از ورود به سیستم باید به شکلی قابل فهم برای الگوریتم‌ها تبدیل شوند. در همین راستا تغییراتی در قالب پیش‌پردازش بر روی این داده‌ها اعمال می‌شود. از آن جایی که داده‌های این پژوهش از سایت سهامیاب گردآوری شده و حاصل تعامل کاربران می‌باشد در نتیجه ساختار مناسبی برای فرآیند تحلیل احساسات و ورود به شبکه عصبی ندارد، بنابراین انجام عملیات پیش‌پردازش بر روی این داده‌ها ضروری است.

پیش‌پردازش داده (Data Preprocessing) به مرحله‌گفته می‌شود که در آن داده‌ها برای داده کاوی آماده می‌شود. باتوجه به اینکه داده‌های تولید شده توسط کاربران فضای اینترنت، دارای نواقصی هستند که باعث به وجود آمدن مشکلاتی در داده کاوی می‌شود؛ بنابراین قبل از هر گونه پردازش روی این داده‌ها، می‌بایست عملیات پیش‌پردازش (Preprocessing) صورت گیرد که طی آن داده‌های خام با اعمال تغییراتی مانند تبدیل کردن اعداد به کلمات و یا حذف کردن اعداد از داده‌های متند، پاک کردن علائم و فاصله خالی ... به داده‌های مناسب به منظور فرآیند تحلیل احساسات تبدیل می‌شوند.

یکی از کتابخانه‌های اصلی پایتون برای آماده‌سازی و پیش‌پردازش داده‌ها، پandas (Pandas) است که کارایی بالا، ساختاری با قابلیت استفاده آسان و ابزارهای Pandas تحلیل داده برای زبان برنامه‌نویسی پایتون را فراهم می‌کند. توابع گوناگون به ساده‌سازی فرایند پیش‌پردازش داده‌ها کمک قابل توجهی می‌کنند. در واقع، می‌توان گفت پandas یک کتابخانه قدرتمند برای تحلیل، و پیش‌پردازش ساختارهای (PreProcessing) داده‌ها است. این کتابخانه می‌تواند داده‌ها را با بهره‌گیری از DataFrame و Series که ارائه می‌کند، به قالبی که برای تحلیل داده‌ها مناسب هستند، مبدل سازد.

توجه می‌تواند به گره فعلی در به دست آوردن محتوای کلیدی فعلی که باید به آن توجه شود، کمک کند.

میت و همکاران [۱۲] از تحلیل احساسی در اخبار بازار سهام برای پیش‌بینی استفاده کرد. آن‌ها هم‌چنین از خروجی تحلیل احساسی در الگوریتم‌های یادگیری ماشین برای تجزیه و تحلیل قیمت سهام استفاده کردند. مشابه این تحقیقات که روی تحلیل احساسات کار کرده اند در منابع [۱۳-۱۴] نیز به چشم می‌خورد.

صدر و همکاران [۱۵] لایه ادغام در شبکه پیچشی را با شبکه عصبی برگشتی جایگزین کردن تا بتوانند و استنگی‌های طولانی مدت را استخراج کرده و زیان اطلاعات محلی را کاهش دهند. آن‌ها با پیشنهاد یک شبکه شرف چند نمایی از ویژگی‌های میانی استخراج شده از شبکه‌های عصبی پیچشی و برگشتی برای انجام طبقه‌بندی استفاده می‌کنند. آن‌ها اذعان داشتند که شبکه‌های عصبی ژرف مختلف به دلیل ساختارهای متمایز قادر به استخراج انواع مختلف ویژگی‌ها هستند، بنابراین در مدل پیشنهادی، ویژگی‌های استخراج شده از شبکه‌های عصبی ناهمگن را با استفاده از طبقه‌بندی چندنامایه ترکیب کردن تا با در نظر گرفتن ارتباط بین آن‌ها، بتوانند عملکرد تحلیل گر احساسات در سطح متنی را بهبود دهند.

سلام و همکاران [۱۶] فیلتینگ مشارکتی را براساس تحلیل احساسی با استفاده از یک مجموعه داده عربی برای ارائه توصیه‌هایی برای کتاب‌ها پیشنهاد کرده‌است. روش پیشنهادی دقت سیستم توصیه عربی را بهبود بخشیده و میانگین مقادیر خط را از نظر RMSE و MAE به ترتیب به ۰.۵۸۳ و ۰.۵۵۸ داده‌است.

در تحقیقات دیگری تحلیل احساسات بیماران [۱۷] و نیز مشاهده کنندگان فیلم‌ها [۱۸] در سه مدل یادگیری عمیق حافظه کوتاه مدت طولانی (LSTM)، شبکه‌های عصبی عمیق (DNN) و شبکه‌های عصبی کانولوشن (CNN) بررسی شده اند و نتیجه نهایی این بوده است که این روش‌ها مکمل یکدیگر هستند و چه بسا انتظار می‌رود که از ترکیب این روش‌ها نتایج بهتر و جامع تری به دست آید.

۳- روش پژوهش

در این بخش مراحل روش پیشنهادی به تفصیل بیان می‌شود.

۱- آماده سازی داده‌ها

قدم اول در پیاده سازی مدل پیشنهادی آماده سازی داده‌ها است. آماده کردن داده‌های ورودی یکی از مهم‌ترین مراحل پیاده سازی الگوریتم‌های یادگیری ماشین است. ابتدا برچسب‌گذاری نظرات جمع آوری شده از سایت سهامیاب (www.sahamyab.com) از ابزار مترجم گوگل ایجاد می‌گردد. در آخرین مرحله نظرات انگلیسی و فارسی و برچسب‌های متناظر با هر کدام از این نظرات در یک فایل اکسل با نام sahamyab_dataset ذخیره می‌شوند.

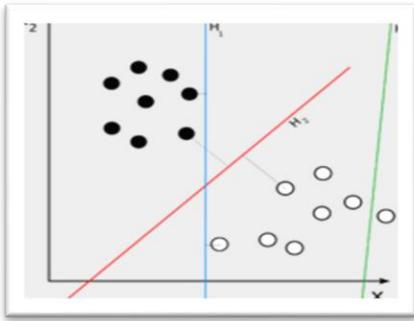
عموماً برای کار با داده‌هایی که در یک فایل اکسل ذخیره شده‌اند به کتابخانه pandas نیاز است. خوب‌بختانه، پandas متدۀای زیادی را فراهم می‌کند که می‌توان از آن‌ها برای بارگذاری داده‌ها از چنین منابعی در دیتافریم پandas استفاده کرد. پandas از تابع read_excel نیز استفاده می‌کند که می‌تواند برای خواندن داده‌های Excel در یک دیتافریم پandas استفاده شود.

مجموعه داده‌ای که در این پژوهش استفاده می‌شود شامل نظرات کاربران سایت سهامیاب در خصوص سهام چند شرکت فعال بورس تهران است که از وب سایت سهامیاب جمع آوری شده‌اند. در جدول ۱ نمای کلی این مجموعه داده آمده است.

روش های نسبتاً جدیدی است که در سال های اخیر کارایی خوبی نسبت به روش های قدیمی تر برای طبقه بندی نشان داده است. پیش از آن که در صحبت و بررسی در مورد ماشین های بردار پشتیبان فراتر برویم؛ باید با یک سری از مفاهیم مربوطه آشنایی مختصری پیدا کنیم

۱-۴- خط یا ابر صفحه جدا کننده

هدف پیدا کردن بهترین خط (ابر صفحه) است که دو دسته را از هم جدا کند. مطابق شکل ۱ (سیز) دو دسته را از هم جدا نمی کند اما H1 (آبی) دو دسته را از هم با حاشیه ای کوچک جدا می کند و H2 (قرمز) دو دسته را با حداقل حاشیه از هم جدا می سازد.



شکل ۱- خط یا ابر صفحه جدا کننده

۲- حداقل حاشیه

بر طبق قضیه ای در تئوری یادگیری اگر مثالهای آموزشی به درستی دسته بندی شده باشند، از بین جداده های خطی، آن جداده ای که حاشیه داده های آموزشی را حداقل می کند، خطی تعمیم را حداقل خواهد کرد. این روش به نظر مطمئن ترین راه است و به طور تجربی به خوبی جواب داده و البته تئوری هایی بر مبنای VC dimension وجود دارد که مفید بودن آن را اثبات می کند. دلیل این که SVM روی بزرگترین مرز برای Hyperplane پافشاری می کند این است که قضیه قابلیت عمومیت بخشیدن به الگوریتم را بهتر تامین می کند. این نه تنها به کارایی طبقه بندی و دقت آن روی داده های آزمایشی کمک می کند، فضا را نیز برای طبقه بندی بهتر داده های آتی مهیا می کند. به طور حسی آن مرزی که به صورت بخشی از فضا تعريف می شود یا همان تفکیک بین دو کلاس به وسیله Hyperplane تعریف می شود. همین تعريف هندسی به ما اجازه می دهد تا کشف کنیم که چگونه مرزها را بیشینه کنیم و لو این که تعداد بیشماری Hyperplane داشته باشیم و فقط تعداد کمی، شایستگی راه حل برای SVM دارند.

۳- بردار پشتیبان

شکل ۲ ابر صفحه ای با حداقل حاشیه برای یک ماشین بردار پشتیبان که با نمونه داده هایی از دو دسته یادگرفته شده است را نمایش می دهد. داده هایی که بر روی آبر صفحه حاشیه قرار دارند بردارهای پشتیبان نام دارند به عبارتی نزدیک ترین داده های آموزشی به ابر صفحه های جدا کننده بردار پشتیبان نامیده می شوند.

یک Series مشابه با آرایه یک بعدی است. Series می تواند داده ها از هر نوعی را ذخیره کند. مقادیری که در Series قرار می گیرند قابل تغییر هستند؛ اما اندازه Series پانداس، غیر قابل تغییر است. به اولین عنصر در Series، اندیس صفر تخصیص داده می شود و اندیس آخرین عنصر در Series برابر با N-1 است که در آن، N تعداد کل عنصرهای موجود در سری است. ساختار داده دیتابریم (DataFrame) در پانداس را می توان به عنوان یک جدول در نظر گرفت. دیتابریم، داده ها را در سطوحها و ستون ها سازمان دهی می کند و از آن ها یک ساختار داده دو بعدی می سازد. ستون ها می توانند حاوی مقادیری از انواع گوناگون باشند و در عین حال، اندازه دیتابریم قابل تغییر است؛ بنابراین می توان آن را ویرایش کرد. برای ساخت دیتابریم، می توان کار را از پایه شروع کرد و یا ساختار داده های مانند آرایه های (NumPy) را به یک دیتابریم تبدیل کرد. ساختاری که در اینجا استفاده شده است ساختار DataFrame است.

پس از این که فایل اکسل مجموعه داده ایجاد شد برای انجام عملیات پیش پردازش به برنامه وارد می شود. این فایل اکسل بیانگر نظرات فارسی، نظرات انگلیسی و برچسب متناظر با هر کدام از این نظرات است. ابتدا با استفاده از کتابخانه Pandas فایل مجموعه داده خوانده و آماده پیش پردازش می شود. بداین صورت که تعدادی لیست واژه (Stopword) ایجاد شده حذف می شوند و با استفاده ازتابع Replace عالم نگارشی موجود در متن نظرات پاک می شوند. سپس یک لغتنامه از کلمات موجود ساخته می شود و بعد از این که عملیات نرم افزاری روی این کلمات صورت گرفت اماده ورود به الگوریتم های یادگیری می شوند.

از آن جایی که ورودی شبکه های عصبی به صورت عدد است، لغت نامه ای که در این پژوهش استفاده می شود با استفاده از اندیس متناظر کلمات ایجاد می شود. به این منظور برای هر کدام از لغات یک اندیس عددی در نظر گرفته می شود. هرنظر با لیستی از اعداد صحیح بیان می شود. با توجه به این که طول داده های ورودی شبکه های عصبی باید یکسان باشد با استفاده ازتابع Pad-Sequence از کتابخانه Keras عملیات نرم افزاری روی نظرات انجام می شود و طول تمام نظرات یکسان و برابر عدد ۳۰ می شود.

مرحله آخر تقسیم داده ها به سه دسته آموزش، اعتبارسنجی و آزمون است. در این پژوهش داده ها به نسبت های ۶۴ درصد و ۱۶ درصد از کتابخانه Train_Test_Split از کتابخانه sklearn استفاده شده است. به این صورت که با آزمون (Test) و ۸۰ درصد باقیمانده با نسبت ۸۰ به ۲۰ برای آموزش (Train) و اعتبارسنجی (Validation) تقسیم بندی شده اند.

۴- الگوریتم های سنتی یادگیری ماشین

یکی از اهداف این پژوهش مقایسه مدل پیشنهادی خود با مدل های سنتی یادگیری ماشین جهت بررسی دقت و کارایی است. برای بررسی این هدف تعدادی از الگوریتم های سنتی یادگیری ماشین مانند KNN، SVM، درخت تصمیم و بیزین ساده با استفاده از کتابخانه Scikit Learn پیاده سازی می شوند. از کتابخانه Sklearn کتابخانه های متن باز، مفید، پر کاربرد و قادر ترند در زبان برنامه نویسی پایتون است که برای اهداف یادگیری ماشین به کار می رود. این کتابخانه ابزارهای کاربردی زیادی به منظور یادگیری ماشین و مدل سازی آماری داده ها همچون طبقه بندی (Classification)، رگرسیون، خوشه بندی و کاهش ابعاد فراهم می کند. این کتابخانه که به طور عمده توسط زبان پایتون ارائه شده، بر پایه کتابخانه های Matplotlib و Scipy.Numpy طراحی شده است.

۱- ماشین بردار پشتیبان

ماشین بردار (Support Vector Machin) یکی از روش های یادگیری با نظرات است که از آن برای طبقه بندی و رگرسیون استفاده می کند. این روش از

چند کلاسه را از طریق مقایسه و طبقه‌بندی به صورت یک به یک (یک برجسب در مقایسه با سایر نمونه‌ها) انجام می‌دهد. پارامتر kernel مقداری اختیاری است و پیش فرض آن rbf است. این پارامتر تعیین کننده نوع kernel به کار گرفته شده در الگوریتم است و می‌تواند یکی از مقادیر linear, rbf, poly و sigmoid و precomputed را بگیرد که مقدار پیش‌فرض rbf است. همانطور که شکل ۳ نشان می‌دهد صحت اجرای این الگوریتم بر روی داده‌های پژوهش برابر با ۶۱ درصد است.

	precision	recall	f1-score	support
Negative	0.50	0.22	0.30	79
Positive	0.64	0.87	0.73	126
accuracy			0.61	205
macro avg	0.57	0.54	0.52	205
weighted avg	0.58	0.61	0.57	205

شکل ۳- نمایی از خروجی الگوریتم SVM

الگوریتمی که برای دسته‌بندی داده‌ها استفاده شود، در نهایت هر نمونه عضو یکی از این دو دسته (Class) دسته‌بندی خواهد شد؛ بنابراین برای هر نمونه داده، یکی از چهار حالتی که در ادامه بیان شده، ممکن است اتفاق بیفتد.

*نمونه عضو دسته مثبت باشد و عضو همین کلاس تشخیص داده شود. مثبت

صحیح یا (True Positive)

*نمونه عضو کلاس منفی باشد و عضو کلاس منفی تشخیص داده شود. منفی

کاذب یا (False Negative)

*نمونه عضو کلاس منفی باشد و عضو همین کلاس تشخیص داده شود. منفی

صحیح یا (True Negative)

*نمونه عضو کلاس منفی باشد و عضو کلاس مثبت تشخیص داده شود. مثبت

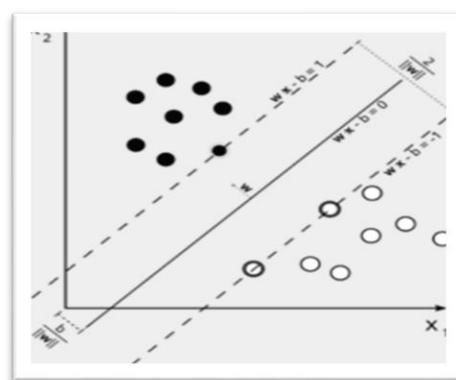
کاذب یا (False Positive)

پس از اجرای الگوریتم دسته‌بندی، با توجه به توضیحات و تعاریف ذکر شده، می‌توان عملکرد یک طبقه‌بند را به کمک جدول ۲ با عنوان جدول یا ماتریس درهم ریختگی (Confusion Matrix) بررسی کرد. ماتریس درهم ریختگی، نتایج حاصل از طبقه‌بندی را بر اساس اطلاعات واقعی موجود، نمایش می‌دهد. حال بر اساس این مقادیر می‌توان معیارهای مختلف ارزیابی دسته بند و اندازه‌گیری دقت را تعریف کرد. پارامتر صحت (Accuracy)، متداول‌ترین، اساسی‌ترین و ساده‌ترین معیار اندازه‌گیری کیفیت یک دسته‌بند است و عبارت است از میزان تشخیص صحیح دسته‌بند در مجموع دو دسته. این پارامتر در واقع نشان‌گر میزان الگوهایی است که درست تشخیص داده شده‌اند.

جدول ۲- ماتریس درهم ریختگی

		برچسب پیش‌بینی شده	
		منفی	مثبت
منفی	TN	FN	
	FP	TP	برچسب شناخته شده

در این پژوهش ماتریس درهم ریختگی با نمودار Heat Map (نقشه حرارتی) نمایش داده می‌شود. Heat Map یک نمایش گرافیکی داده است، نقشه‌های حرارتی برای شناسایی الگوها در مقادیر زیاد داده در یک نگاه بسیار مفید هستند. نقشه‌های حرارتی اغلب نقطه شروع خوبی برای تحلیل‌های پیچیده‌تر است؛ اما همچنین یک تکنیک تجسم چشم نواز است که آن را به ابزاری مفید برای ارتباط تبدیل می‌کند.



شکل ۲- بردار پشتیبان

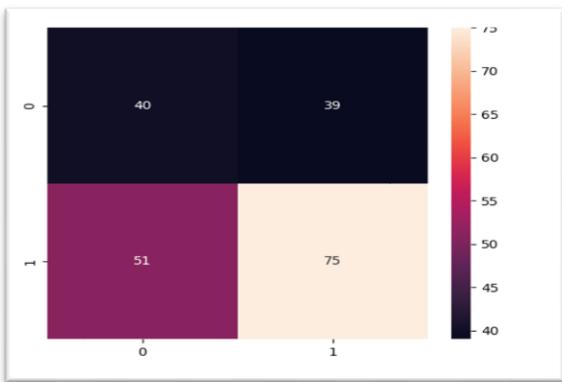
۴-۱-۴- ماشین بردار پشتیبان خطی

ماشین بردار پشتیبان یک روش یادگیری نسبتاً جدید است که اغلب برای کلاس‌بندی باینری مورد استفاده واقع می‌شود. فرض کنید \mathcal{S} مشاهده داریم که هر مشاهده مشتمل بر زوج‌هایی است که در آن بردار ورودی و یک مقدار دو وضعیتی (۱- یا +۱) وجود دارد. ایده ماشین بردار پشتیبان می‌کوشد، ابر صفحاتی در فضا رسم کند که عمل تمایز نمونه‌های کلاس‌های مختلف داده‌ها را به طور بهینه انجام دهد.

مبناً کاری دسته بندی کننده SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کنیم خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد. حل معادله پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های QP که روش‌های شناخته شده‌ای در حل مسائل محدودیت دار هستند صورت می‌گیرد. قبل از تقسیم خطی برای این که ماشین بتواند داده‌های با پیچیدگی بالا را دسته‌بندی کند داده‌ها را با استفاده ازتابع Phi به فضای با ابعاد خیلی بالاتر می‌بریم. برای این که بتوانیم مسئله ابعاد خیلی بالا را با استفاده از این روش‌ها حل کنیم از قضیه دوگانی لاگرانژ برای تبدیل مسئله مینیمم‌سازی موردنظر به فرم دوگانی آن که در آن به جای تابع پیچیده Phi که ما را به فضای با ابعاد بالا می‌برد، تابع ساده‌تری به نام تابع هسته که ضرب برداری تابع Phi است ظاهر می‌شود، استفاده می‌کنیم. از توابع هسته مختلفی از جمله هسته‌های نمایی، چند جمله‌ای و سیگموید می‌توان استفاده نمود. با فرض این که دسته‌ها به صورت خطی جداپذیر باشند، ابر صفحه‌هایی با حداقل حاشیه (Maximum Margin) را به دست می‌آورد که دسته‌ها را جدا کنند. در مسایلی که داده‌ها به صورت خطی جداپذیر نباشند، داده‌ها به فضای با ابعاد بیشتر نگاشت پیدا می‌کنند تا بتوان آن‌ها را در این فضای جدید به صورت خطی جدا نمود.

در یک فرآیند یادگیری که شامل دو کلاس می‌باشد، هدف SVM پیدا کردن بهترین تابع برای طبقه‌بندی می‌باشد به نحوی که بتوان اعضای دو کلاس را در مجموعه داده‌ها از هم تشخیص داد. معیار بهترین طبقه‌بندی به صورت هندسی مشخص می‌شود، برای مجموعه داده‌هایی که به صورت خطی قابل تجزیه هستند. ماشین بردار پشتیبان از جمله متدهای قدرتمند طبقه‌بندی نظارت شده است. در ابعاد بالا انعطاف‌پذیر است و در مسائل طبقه‌بندی به طور گسترده استفاده می‌شود و از نظر مصرف حافظه کاراست؛ این الگوریتم با ایجاد بردارهایی در فضای داده‌ها به بهترین شکل ممکن تفکیک داده‌ها را انجام می‌دهد. ماشین بردار پشتیبان در ابتدا ابر صفحاتی را تولید می‌کند که نقاط را به شکل صحیح تقسیم می‌کند. سپس میان ابر صفحات آن ابر صفحه‌ای را بر می‌گزیند که نقاط را به بهترین شکل ممکن جدا می‌کند.

دو پارامتر به کار رفته در این الگوریتم SVC از کلاس SVM و Kernel از جنس SVC صورت می‌گیرد. SVC طبقه‌بندی از طریق کلاس String هستند. طبقه‌بندی از طریق کلاس SVC صورت می‌گیرد.



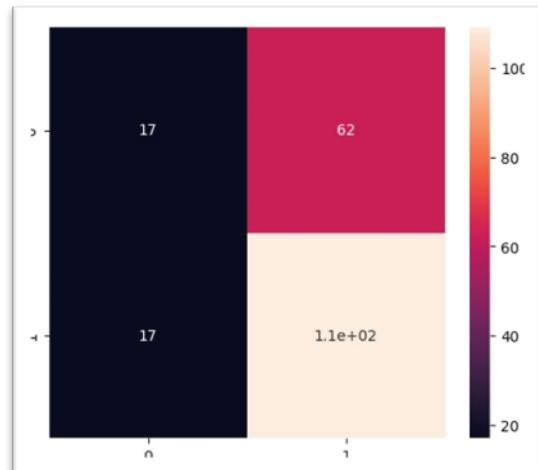
شکل ۶- نمودار Heat Map الگوریتم درخت تصمیم

۴-۳- الگوریتم بیزین ساده
الگوریتم بیزین یکی از الگوریتم های سنتی یادگیری ماشین در فرآیند طبقه بندی داده است که براساس تکنیک های آماری به طبقه بندی این داده ها می پردازد. در این مقاله به دلیل گسسته بودن داده ها از مدل MultinomialNB برای این الگوریتم استفاده شده است. همانطور که شکل ۷ نشان می دهد صحت بدست آمده از اجرای این الگوریتم بر روی داده ها ۵۳ درصد است. شکل ۸ نمودار Heat Map الگوریتم بیزین ساده را نمایش می دهد.

	precision	recall	f1-score	support
Negative	0.40	0.41	0.40	79
Positive	0.62	0.61	0.62	126
accuracy			0.53	205
macro avg	0.51	0.51	0.51	205
weighted avg	0.53	0.53	0.53	205

شکل ۷- خروجی الگوریتم بیزین ساده

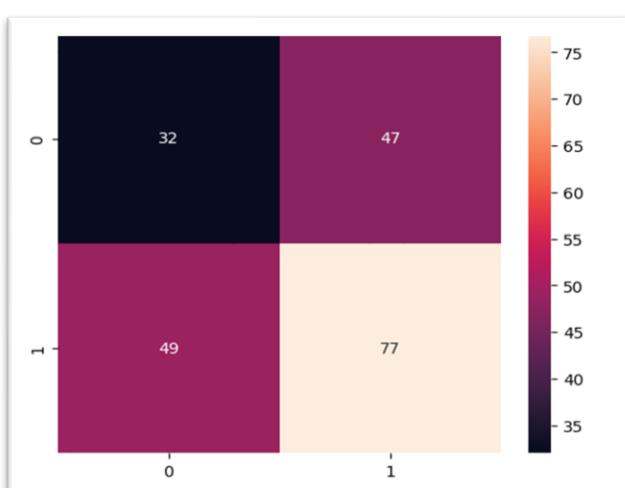
این نقشه اساساً شبکه ای از مربع های رنگی است که هر مربع یا صندوقچه، تقاطع مقادیر دو متغیر را نشان می دهد که در امتداد محور های افقی و عمودی امتداد دارند. محور عمودی مقادیر واقعی و محور افقی مقادیر پیش بینی شده توسط مدل را نمایش می دهد. ماهیت دو بعدی نقشه رنگی به خاطر به نمایش گذاشتن اطلاعات ماتریس می باشد. شکل ۴ نمودار Heat Map SVM را نشان می دهد.



شکل ۴- نمودار Heat Map لگوریتم SVM

۴-۲- الگوریتم درخت تصمیم

الگوریتم درخت تصمیم از محبوب ترین و کاربردی ترین الگوریتم ها در زمینه طبقه بندی داده ها است. این الگوریتم با ساختار درختی خود به جداسازی و طبقه بندی داده ها می پردازد. در این مقاله ابتدا یک نمونه از کلاس این الگوریتم ساخته می شود سپس فرآیند اجرا و آزمون انجام می شود. همانطور که شکل ۵ نشان می دهد صحت اجرای این الگوریتم بر روی داده های پژوهش برابر با ۵۶ درصد است و شکل ۶ نمودار Heat Map الگوریتم درخت تصمیم را نشان می دهد.



شکل ۸- نمودار Heat Map الگوریتم بیزین ساده

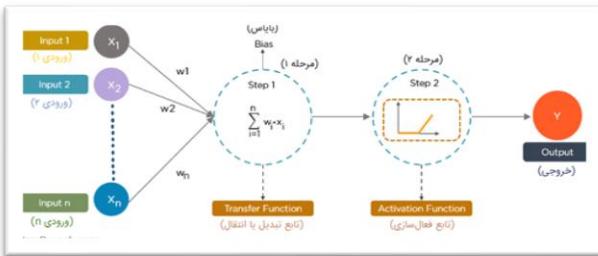
	precision	recall	f1-score	support
Negative	0.44	0.51	0.47	79
Positive	0.66	0.60	0.62	126
accuracy			0.56	205
macro avg	0.55	0.55	0.55	205
weighted avg	0.57	0.56	0.57	205

شکل ۵- نمایی از خروجی الگوریتم درخت تصمیم

۴-۴- الگوریتم نزدیک ترین همسایه (KNN)

برای پیاده سازی الگوریتم KNN در پایتون از کتابخانه Scikit-Learn استفاده می شود که یکی از پر کاربرد ترین الگوریتم ها در حوزه یادگیری ماشین سنتی است که هم برای مسایل رگرسیون و هم طبقه بندی کاربرد دارد. همانطور که شکل ۹ نشان می دهد صحت اجرای این الگوریتم بر روی داده های این مقاله ۵۹ درصد است.

“گره” نیز شناخته می شود. این گره ها در سه لایه ورودی، مخفی و خروجی در کنار هم چیده شده اند. شکل ۱۲ ساختار شبکه عصبی را نمایش می دهد.



شکل ۱۲ - ساختار شبکه عصبی

داده ها، اطلاعاتی را در قالب ورودی به هر گره ارائه می دهند. گره، ورودی ها را در وزن های تصادفی ضرب می کند، آن ها را محاسبه کرده و یک بایاس به آن اضافه می کند. در نهایت، توابع غیرخطی، که به آن ها “تابع فعال سازی” گفته می شود، برای تعیین این که کدام نورون شلیک کند، اعمال می شوند.

در این مقاله الگوریتم های شبکه عصبی با استفاده از کتابخانه Keras ساخته می شوند که یک کتابخانه یادگیری عمیق منبع باز و یکی از بهترین کتابخانه های پایتون محسوب می شود. این کتابخانه آزمایش سریع با مدل های یادگیری عمیق را امکان پذیر می کند و از شبکه های کانولوشنال و شبکه های تکراری و همچنین ترکیبی از این دو پشتیبانی می کند. این کتابخانه پایتون به طور گسترده برای برنامه هایی مانند تشخیص و پردازش تصویر، پردازش زبان طبیعی و تشخیص گفتار استفاده می شود.

یکی دیگر از موارد استفاده بالقوه برای Keras برای پردازش زبان طبیعی (NLP) است. از Keras می توان برای ساخت مدل هایی استفاده کرد که می توانند متن زبان طبیعی را درک و تفسیر کنند. این مدل ها را می توان با مجموعه های از متن، مانند مقاله های خبری یا کتاب، آموزش داد و سپس برای تحلیل و تفسیر متن جدید استفاده کرد. این می تواند توسط یک سیستم خودکار برای پردازش و درک پرس و جوها یا دستورات زبان طبیعی استفاده شود.

یک API سطح بالا برای ساخت مدل های یادگیری عمیق است. مجموعه ای از کلاس ها و عملکردها را برای کمک به ایجاد و آموزش مدل های یادگیری عمیق ارائه می دهد.

کلاس و توابع اصلی در کتابخانه Keras عبارت اند از:
• Klass این کلاس برای ایجاد مدل شبکه عصبی که از لایه ها تشکیل شده است استفاده می شود.
• Sequential این کلاس برای ایجاد یک پشته خطی از لایه ها استفاده می شود.
• Dense از این کلاس برای ایجاد یک لایه متصل متراکم استفاده می شود.
• Activation این کلاس برای افزودن یک تابع فعال سازی به یک لایه استفاده می شود.

از این کلاس برای ایجاد یک لایه کانولوشنال استفاده می شود.
• Convolutional

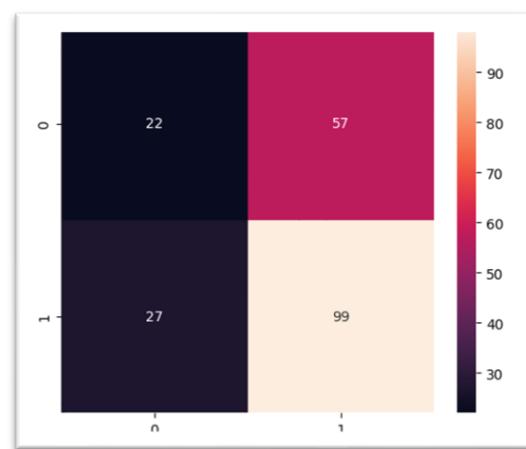
این کلاس برای ایجاد یک لایه Max pooling استفاده می شود.
• MaxPooling

این کلاس برای ایجاد لایه Dropout استفاده می شود.
• Dropout از این کلاس برای صاف کردن لایه ورودی استفاده می شود.
• Flatten این کلاس برای تعریف بهینه ساز مورد استفاده برای آموزش مدل استفاده می شود.
• Optimizers

	precision	recall	f1-score	support
Negative	0.45	0.28	0.34	79
Positive	0.63	0.79	0.70	126
accuracy			0.59	205
macro avg	0.54	0.53	0.52	205
weighted avg	0.56	0.59	0.56	205

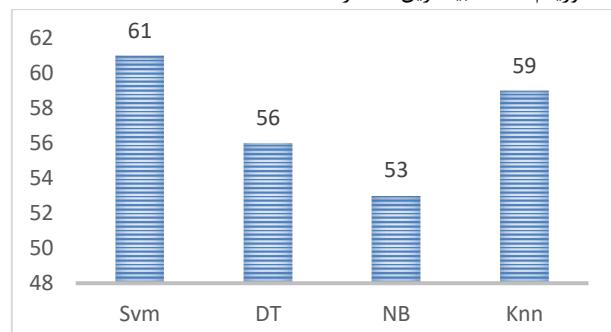
شکل ۹ - خروجی الگوریتم KNN

شکل ۱۰ نمودار Heat Map KNN را نشان می دهد.



شکل ۱۰ - نمودار Heat Map KNN الگوریتم

شکل ۱۱ دقت الگوریتم های یادگیری ماشین سنتی را مقایسه می کند و نشان می دهد الگوریتم SVM بیشترین دقت را داشته است.



شکل ۱۱ - مقایسه دقت الگوریتم های یادگیری ماشین سنتی

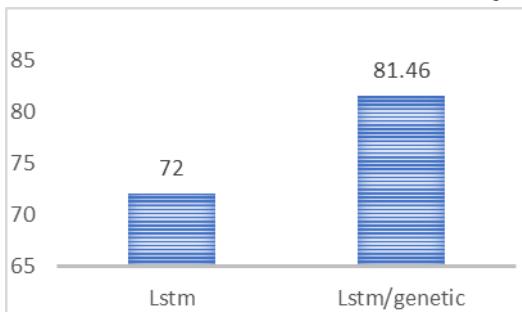
۵- مدل های شبکه عصبی

شبکه های عصبی (Neural Network) در واقع دسته ای از الگوریتم های یادگیری ماشین هستند که برای شناسایی و تشخیص الگوها به کار می روند. یک شبکه عصبی توسط ورودی ها آموزش داده می شود و شامل لایه ورودی، پنهان و خروجی است و هر کدام از عصب ها دارای مقدار آستانه و تابع فعال سازی می باشند که منجر به خروجی می شوند. نتیجه به دست آمده با خروجی مورد انتظار مقایسه می شود که این دو مقدار باید نزدیک به هم باشند. مدل باد می گیرد که وزن ها و مقدار آستانه را طوری تنظیم کند که خروجی درست دریافت کند. یک شبکه عصبی، مانند مغز انسان ساختار یافته است و از نورون های مصنوعی تشکیل شده است که با عنوان

تعريف کنیم. در نهایت، باید عملگرهای زننده جهش، جابجایی و ترکیب را بر روی جمعیت اعمال کنیم تا نسل های جدیدی از شبکه های LSTM را تولید کنیم. به طور خلاصه، می توان گفت که الگوریتم زننده بر LSTM یک روش بهینه سازی است که با شبیه سازی فرایند تکامل، می تواند بهترین شبکه LSTM را برای پیش بینی سری های زمانی چند متغیره انتخاب کند. این روش می تواند به شبکه LSTM کمک کند تا از اطلاعات گذشته بهتر استفاده کند و پیش بینی های دقیق تری ارائه دهد. انتخاب هایپر پارامتر مناسب یکی از مهم ترین مسائل در پیاده سازی مدل LSTM در مرحله ای آموزش است، دست یافتن به این هایپر پارامتر که منجر به یک الگوریتم بهینه شود کاری پیچیده است. در این مقاله پس از پیاده سازی مدل LSTM، به منظور بهینه سازی عملکرد این مدل از الگوریتم فرا ابتکاری زننده استفاده می شود. بدین منظور ابتدا مقادیر مجاز برای هر پارامتر تعیین می شود. مقادیر مجاز برای این الگوریتم به شرح زیر است:

- Unit[۶۴, ۳۲, ۸]
- Activation: ["sigmoid", "relu", "selu", "elu", "softmax", "softplus", "tanh"]
- Optimizer: ["adamax", "adam", "rmspropo", "nadam"]
- Loss: ["binary_crossentropy", "mse", "mae"]
- Batch[۶۴, ۳۲, ۱۶, ۸, ۴, ۲]

با استفاده از الگوریتم فرا ابتکاری هایپر پارامترهای تعداد واحد، تابع فعال ساز، بهینه ساز، تابع ضرر و اندازه بسته ها بهینه می گردد. سپس با استفاده از این مقادیر مجاز یک جمعیت اولیه به تعداد ۱۰ کروموزوم ساخته می شود، هر کدام از ژن های یک کروموزوم شامل یک مقدار مجاز از هایپر پارامترهاست که انتخاب این مقادیر به صورت تصادفی است؛ بنابراین هر کدام از کروموزومها شامل ترکیبی بهینه از هایپر پارامتر می باشد که در آموزش مدل استفاده می شود. سپس ارزیابی کروموزوم ها با تابع برآش انجام می شود به این صورت که مدل LSTM به ازای هر کروموزوم یک بار اجرا می شود و بعد از آموزش با داده های آزمون ارزیابی می شود. بعد از ارزیابی جمعیت با استفاده از چرخ رولت کروموزوم های ارزنده بعنوان والد انتخاب می شوند. در مرحله بعدی کروموزوم های والد با روش چند نقطه ای باهم ترکیب شده و کروموزوم جدید که هایپر پارامترهای والدین را به ارث برده ایجاد می شود و در نهایت این کروموزوم بعد از جهش به جمعیت اضافه می شود. سپس شرط پایانی بررسی می شود به این صورت که تازمانی که صحت اجرای مدل به مقدار آستانه که در این جا ۹۹ درصد است نرسیده باشد و یا تعداد نسل های الگوریتم که در این مقاله به تعداد ۵۰ نسل است به پایان نرسیده باشد، اجرای الگوریتم ادامه می یابد در غیراین صورت الگوریتم پایان می یابد و ژن های موجود در آن کروموزوم به عنوان هایپر پارامتر بهینه معرفی شده و در مرحله بعد ارزیابی می شوند و بهترین عضو آن ها به عنوان هایپر پارامتر ارزنده معرفی می شود و مدل LSTM را بهینه می کند. شکل ۱۴ ۱۴ نشان می دهد که صحت عملکرد این الگوریتم بر روی داده های این مقاله ۸۱/۴۶ درصد است در حالیکه پس از اجرای الگوریتم LSTM به تنها ۷۲ صحت درصد بدست آمد.



شکل ۱۴ - نمودار مقایسه LSTM و پیاده سازی LSTM با الگوریتم زننده

Losses* این کلاس برای تعریفتابع ضرر مورد استفاده برای محاسبه خطای مدل استفاده می شود.

Metrics* از این کلاس برای تعریف معیارهای لازم استفاده می شود. در این قسمت مدل های شبکه عصبی LSTM و BERT که در این مقاله استفاده شده اند شرح داده می شوند. نظر به این که در تمام این مدل ها لایه تعبیه ساز یکسان است، پیاده سازی این لایه نیز توضیح داده می شود. این لایه در اولین لایه معماری مدل های شبکه عصبی عمیق قرار گرفته و بعنوان لایه ورودی در نظر گرفته می شود. برای پیاده سازی لایه تعبیه ساز در پایتون از لایه Embedding Keras تعریف شده است، استفاده می شود. پارامترهای این لایه که شامل تعداد لغات، اندازه بردار متراکم و طول نظرات که همان داده های ورودی هستند مقدار دهی می شوند. مقدار ۳ برای اندازه بردار متراکم و طول نظرات در نظر گرفته شده است.

۱-۵-۱ مدل LSTM

الگوریتم LSTM یک نوع شبکه عصبی بازگشتی است که می تواند از اطلاعات گذشته در پیش بینی آینده استفاده کند. این شبکه دارای یک حافظه داخلی است که می تواند اطلاعات مربوطه را نگه دارد و اطلاعات نامربوط را فراموش کند. پیاده سازی الگوریتم LSTM در پایتون نیاز به استفاده از کتابخانه های مانند Tensorflow (PyTorch) یا پایتون (Tensorflow) دارد که امکان ساخت و آموزش شبکه های عصبی را فراهم می کنند. همچنین باید معماری و پارامترهای شبکه LSTM را با توجه به مسئله مورد نظر تعیین کرد. برای این کار، می توان از الگوریتم های فرالبتکاری (Metaheuristic) مانند الگوریتم زننده (Genetic Algorithm) که می توانند به بهینه سازی پارامترهای شبکه LSTM کمک کنند استفاده کرد. این مدل به صورت ترتیبی ساخته می شود. لایه تعبیه ساز به اولین لایه اضافه شده و سپس یک لایه LSTM به تعداد ۱۶ واحد می سازد و بعد از آن یک لایه Dense با یک نورون برای تولید خروجی قرار می دهد. تابع Sigmoid تابع فعال ساز در خروجی این مدل است. در مرحله آخر مدل با بهینه ساز adam، تابع ضرر binary-crossentropy و معیار Accuracy کامپایل می شود. همانطور که شکل ۱۳ نشان می دهد صحت عملکرد این مدل برای تشخیص قطبیت نظرات کاربران سایت سهامیاب ۷۲ درصد است.

	precision	recall	f1-score	support
Negative	0.65	0.61	0.63	79
Positive	0.76	0.79	0.78	126
accuracy			0.72	205
macro avg	0.71	0.70	0.70	205
weighted avg	0.72	0.72	0.72	205

```
/7 [=====] - 05 5ms/step - loss: 3.5783 - accuracy: 0.7220
3.578272581100464, 0.7219512462615967]
```

شکل ۱۳ - نمایی از خروجی الگوریتم LSTM

۱-۵-۲ بهینه سازی الگوریتم LSTM با زننده

الگوریتم زننده یک تکنیک بهینه سازی است که الهام گرفته از فرایند تکامل در طبیعت است. این الگوریتم با تولید و انتخاب جمعیت هایی از جواب های محتمل برای یک مسئله، سعی می کند به جواب بهینه برسد. پیاده سازی الگوریتم زننده بر LSTM به این معنی است که می خواهیم معماری و پارامترهای شبکه LSTM را با استفاده از الگوریتم زننده تنظیم کنیم. به این ترتیب، می توانیم بهترین شبکه LSTM را برای پیش بینی سری های زمانی چند متغیره پیدا کنیم. برای این کار، باید ابتدا جمعیت اولیه ای از شبکه های LSTM با معماری ها و پارامترهای مختلف تولید کنیم. سپس، باید تابع هدف و تابع برآزندگی را برای ارزیابی عملکرد شبکه ها

استفاده می کند. با استفاده از این نمودارها می توان تمام محاسبات انجام شده در طول آموزش را جمع آوری و توصیف کرد. البته مزایای گراف محدود به این موارد نیست. از دیگر مزایای گراف ها می توان به اجرا روی چندین CPU، GPU و حتی سیستم عامل های تلفن های همراه اشاره کرد. نمودارها قابلیت ذخیره دارند و می توان آن ها را برای استفاده های بعدی ذخیره کرد. تمامی محاسبات درون نمودارها به تائسون ها وابسته است و به وسیله آن ها انجام می شود. هر تائسون یک گره و یک لبه دارد. گره وظیفه انجام عملیات ریاضی را بر عهده دارد و خروجی ها را تولید می کند. لبه ها نیز وظیفه توضیح روابط ورودی و خروجی را بر عهده دارند.

الگوریتم BERT یک مدل هوش مصنوعی است که برای درک بهتر زبان طبیعی و معنای کلمات در جملات طراحی شده است. این الگوریتم از تکنیکی به نام ترانسفورمر استفاده می کند که به آن اجزه می دهد تا به صورت دو جهته متن را تحلیل کند. یعنی هم از سمت چپ به راست و هم از راست به چپ متن را بخوان و ارتباط بین کلمات را در نظر بگیرد که باعث می شود مفهوم پنهان کلمات را درک BERT کند و نتایج دقیق تری را به کاربران ارائه دهد، به همین دلیل الگوریتم BERT نیازی به پیش پردازش متن ندارد چرا که پیش پردازش متن عملیاتی است که برای تبدیل متن به یک فرم مناسب برای مدل های هوش مصنوعی انجام می شود.اما الگوریتم BERT می تواند متن را به صورت خام و بدون تغییر دریافت کند و با استفاده از ترانسفورمر آن را به بردارهای عددی تبدیل کند، این بردارها نشان دهنده معنای کلمات در جمله هستند و می توانند برای تشخیص احساسات استفاده شوند. برای پیاده سازی الگوریتم BERT در این مقاله از کتابخانه Transformers استفاده می شود. این کتابخانه شامل ابزارهای مربوطه است. ابتدا مدل Huggingface Tokenizer که در سایت PreTrained BERT و قبل با داده های متنوع پیش آموزش دیده بارگزاری می شود و در ادامه با داده ها و اهداف پیروزه تطبیق داده می شود. Huggingface یک پلتفرم مرکزی است که به ما امکان استفاده از جدیدترین و بهترین مدل ها و دیتاست های هوش مصنوعی را می دهد. سپس پارامترهای مدل مانند batch_size.max_length و تعیین می گردد، دسترسی به Gpu بررسی می گردد و در صورت وجود دیتاهای موجود در هر batch به Gpu انتقال می بیند و یک کلاس برای Tokenizer کردن داده ها ساخته می شود. این کلاس حداکثر طول جملات، Data و Tokenizer را می گیرد و دیتای موردنیاز برای ورود به مدل BERT را می سازد. با استفاده از Tokenizer متن نظرات را به بردارهای قابل فهم برای مدل تبدیل می شود. بردار شامل یکسری صفر و یک است که اهمیت / عدم اهمیت هر توکن را نشان می دهد. متغیر attention_mask میان توکن های Pad و با معنی تفاوت ایجاد می کند، صفر برای توکن های Pad و یک برای توکن های با معنی خواهد بود.

داده ها که بصورت جفت های متن و برچسب هستند خوانده می شوند و با استفاده ازتابع Train-Test-Split تقسیم بندی داده ها برای قسمت های Test و Validation و Train انجام می شود. داده های آموزش برای تنظیم دقیق مدل استفاده می شوند، داده های ارزیابی برای اندازه گیری عملکرد مدل BERT و داده های آزمون برای ارزیابی نهایی مدل بر روی داده های جدید استفاده می شوند. سپس برای بهبود عملکرد و به روز رسانی پارامترهای مدل بهینه ساز adam تعریف می گردد، adam سرعت زیادی دارد و حافظه کمی مصرف می کند.

تابع زیان cross entropy loss تعریف می گردد، این تابع برای مسائل دسته بندی بکار می رود. این تابع اختلاف بین دو توزیع احتمال را اندازه گیری می کند: توزیع احتمال پیش بینی شده توسط مدل و توزیع احتمال واقعی که برچسب های هدف را نشان می دهد. سپس ورودی به مدل داده شده و یک لایه خروجی مناسب اضافه می شود که BERT بتواند خروجی موردنظر را تولید کند. هر لایه ترانسفورمر خروجی خود را به لایه بعدی ارسال می کند و درنهایت لایه آخر ترانسفورمر خروجی نهایی را تولید می کند. این خروجی شامل یک بردار برای هر توکن ورودی است که معنای آن را با توجه به بافت جمله نشان می دهد. این بردارها می توانند برای انجام

جدول ۳ بهترین عملکرد به همراه هایپر پارامترهای بهینه آن را نشان می دهد.

جدول ۳- بهترین عملکرد و مقادیر هایپر پارامترهای بهینه

هایپر پارامترهای بهینه						تسلی	صفحت
Unit1	Unit2	activation	optimizer	loss	Batch-size	۲۲	%
۸	۲۲	sigmoid	rmsprop	binary_crossentropy	۴	۸۱/۴۶	

BERT-۵-۳ مدل

پیاده سازی الگوریتم BERT با زبان پایتون یکی از راههایی است که می توان از این الگوریتم پیشرفتی برای پردازش زبان طبیعی استفاده کرد. یکی از روش هایی است که می توانیم از این الگوریتم پیشرفتی برای درک بهتر معنای کلمات و عبارات جستجو شده توسط کاربران استفاده کنیم. این الگوریتم از یک مدل ترانسفورمر دو طرفه استفاده می کند که می تواند با توجه به موقعیت و ارتباط کلمات در یک جمله، معنای آن ها را تشخیص دهد.

برای این کار نیاز به دانستن مفاهیم اساسی پایتون، تنسورفلو و ترانسفورمر است. تنسورفلو یک کتابخانه یادگیری عمیق است که این امکان را فراهم می کند تا مدل های پیچیده را با استفاده از گراف های محاسباتی بسازیم. ترانسفورمر یک کتابخانه است که شامل مجموعه ای از مدل های پردازش زبان طبیعی مبتنی بر BERT و مدل های مشابه است. با استفاده از این کتابخانه، می توانیم BERT را به راحتی بارگذاری کنیم، آموزش دهیم و ارزیابی کنیم.

کتابخانه تنسورفلو در پایتون؛ یک کتابخانه ریاضی نمادین است و با استفاده از داده ها و برنامه نویسی در فعالیت های مختلف شبکه های عصبی استفاده می شود. تنسورفلو مجموعه ای از مدل ها و الگوریتم های یادگیری ماسیون و یادگیری عمیق است. تنسورفلو به ما این امکان را دهد که نمودارها و ساختارهای جریان داده را بسازیم و با در نظر گرفتن ورودی ها به عنوان یک آرایه چند بعدی به نام تنسور نحوه عملکرد آن ها را به صورت نمودار نشان دهیم. هم چنین می توانیم تمامی مراحلی که داده ها طی می کنند را به صورت فلوچارت نمایش دهیم.

معماری تنسورفلو شامل سه بخش پیش پردازش داده ها، ساختن مدل و آموزش مدل و تخمین عملکرد می باشد. این سه مرحله در کنار هم تنسورفلو را به وجود می آورد. تنسورفلو ورودی را به عنوان یک آرایه چند بعدی دریافت می کند. به این آرایه چند بعدی Tensor گفته می شود. در طی چندین فرآیند روی داده های ورودی اعمال می شود و در انتهای به عنوان یک خروجی خارج می شود. علت نام گذاری تنسورفلو نیز به خاطر فرآیندی است که داده ها طی می کنند و تائسون از طریق تعدادی عملیات مشخص جریان پیدا می کند و در انتهای به عنوان خروجی؛ خارج می شود.

نام این کتابخانه از اصلی ترین قسمت اصلی آن یعنی Tensor گرفته شده است. تمامی محاسباتی که در تنسورفلو انجام می شود شامل تائسون است. اگر بخواهیم دقیق تر بگوییم که تائسون از چه چیزی تشکیل شده است، باید بگوییم که تنسور از یک ماتریس چند بعدی تشکیل شده است. این ماتریس می تواند هر نوع داده ای را نمایش دهد. البته این را هم باید بگوییم که درست است که تائسون قابلیت نمایش همه نوع داده را دارد اما تمامی داده های درون یک تائسون باید از یک نوع باشند. تائسون می تواند یک داده ورودی یا نتیجه یک محاسبه باشد. در کتابخانه تنسورفلو در پایتون تمامی عملیات روی نموداری که مجموعه ای از محاسبات متوالی است؛ انجام می شود. هر عملیاتی که انجام می شود را گره عملیات می گویند، تمامی گره ها به یکدیگر متصل هستند. نموداری که در طی عملیات تنسورفلو استفاده می شود؛ تمامی گره ها و اتصالات را نمایش می دهد. کتابخانه تنسورفلو در پایتون از نمودارها

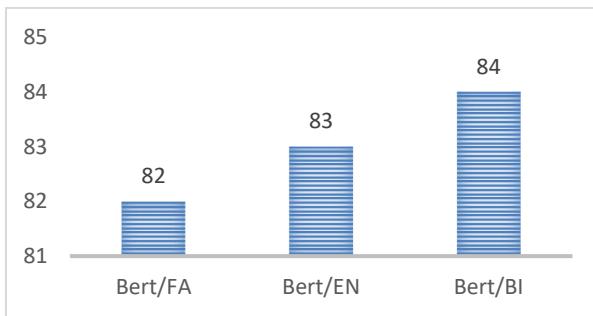
مثل فارسی و انگلیسی، تحلیل کند و معنای آن ها درک کند. این الگوریتم می تواند برای مواردی مثل ترجمه، خلاصه سازی، پرسش و پاسخ و غیره مفید باشد.

الگوریتم BERT دو زبانه در سال ۲۰۱۹ توسط محققان گوگل معرفی شد و بر روی ۱۰۴ زبان مختلف آموزش داده شد. این الگوریتم از یک مدل ترنسفورمر دو طرفه استفاده می کند که می تواند با داده هایی که شامل دو زبان مختلف هستند، سازگار شود. برای استفاده از الگوریتم BERT دو زبانه، می توانیم از کتابخانه ترنسفورمرز پایتون استفاده کنیم. این کتابخانه شامل مدل های پیش آموزش دیده BERT دو زبانه برای زبان های مختلف است. همانطور که در شکل ۱۷ نشان داده شده است صحت عملکرد این مدل برای تشخیص قطبیت نظرات کاربران سایت سهامیاب ۸۴ درصد است.

	precision	recall	f1-score	support
0	0.79	0.78	0.79	79
1	0.87	0.87	0.87	126
accuracy			0.84	205
macro avg	0.83	0.83	0.83	205
weighted avg	0.84	0.84	0.84	205

شکل ۱۷- نمایی از خروجی الگوریتم BERT دو زبانه

شکل ۱۸ نشان می دهد که صحت اجرای الگوریتم BERT دو زبانه، بیشترین مقدار را داشته است.



شکل ۱۸- نمودار مقایسه دقت اجرای الگوریتم BERT

مجموعه داده ای که در این مقاله ارائه شده دارای ۱۰۲۴ نمونه است. هر نمونه از یک نظر به همراه برچسب آن (ثبت یا منفی) و نام سهام شرکت مورد نظر تشکیل شده است. در ابتدا مقایسه الگوریتم های سنتی یادگیری ماشین و عملکرد آن ها بررسی شد. برای این منظور الگوریتم های درخت تصمیم، ماشین بردار پشتیبانی، بیزین ساده و KNN (K-Nearest Neighbors) برای داده های آنها آزمون انجام شدند. بردار پشتیبانی با صحت ۶۱ درصد بهترین عملکرد را در میان الگوریتم های سنتی به دست آورد. در فاز بعدی به منظور مقایسه الگوریتم های یادگیری سنتی با الگوریتم های یادگیری عمیق مدل های LSTM و BERT به زبان فارسی و BERT به زبان انگلیسی طراحی شدند. این مدل ها به ترتیب با صحت های ۷۲ درصد ، ۸۲ درصد و ۸۳ درصد عملکرد بهتری نسبت به الگوریتم های سنتی داشتند. در مرحله بعدی مدل LSTM با استفاده از الگوریتم فرا ابتکاری ژنتیک باهدف بدست آوردن هایپر پارامترهای بهینه پیاده سازی شد. با کمک الگوریتم ژنتیک این مدل به صحتی برابر با ۸۱/۴۶ درصد رسید که درصد نسبت به مدل اولیه LSTM پیشرفت داشت. در فاز پیاپی این مقاله الگوریتم BERT دو زبانه با ترکیب متن فارسی نظرات و معنای

و ظایف مختلفی مانند طبقه بندی استفاده شوند. در مرحله بعدی مدل به حالت آموزش تنظیم می شود. در ابتدا مقدار اولیه خطای آموزش و دقت صفر می گردد و همچنین مقدار گردایان ها برای جلوگیری از اختلال پاک می شود. سپس مدل BERT بر روی داده های آزمون اجرا شده و میزان خطأ و دقت آموزش مدل محاسبه می گردد. پس از مرحله آموزش مدل وارد فاز ارزیابی می شود. تنظیم پارامترها مشابه فاز آموزش صورت می گیرد با این تفاوت که در ارزیابی به محاسبه گردایان نیازی نیست. بعد از اجرای مدل و دریافت خروجی ها، مقدار خطأ و دقت محاسبه می شود و نتایج چاپ می گردد.

پیاده سازی BERT به زبان انگلیسی هم دقیقا مشابه BERT فارسی است با این تفاوت که از یک مدل BERT که روی داده های انگلیسی Pre-Trainrd شده استفاده می شود. این مدل نیز از سایت Huggingface BERT که از مدل پشتیبانی می کند دانلود شده و بارگذاری می گردد و روی داده های آموزش داده می شود. سپس برای تنظیم دقیق مدل BERT یک لایه دسته بندی به انتهای مدل اضافه کرده و پارامترهای مدل با استفاده از داده های آموزش بهینه می شوند و در نهایت مدل BERT روی داده های ارزیابی و آزمون اجرا شده و عملکرد مدل با معیارهای دقت و صحت ارزیابی می گردد. در مدل های BERT به زبان انگلیسی یا فارسی بدون نیاز به کلاس مدل های از پیش آموزش دیده بارگذاری می شوند اما برای پیاده سازی BERT دو زبانه ابتدا یک کلاس برای ساخت مدل ایجاد می شود سپس شخصی سازی می گردد. پس از ساخت کلاس مدل های فارسی و انگلیسی هر کدام جداگانه بارگذاری شده و یک لایه Classifier بعنوان لایه آخر معماری مدل دو زبانه تعریف می شود و برای خروجی لایه آخر دو مدل فارسی و انگلیسی باهم ترکیب می شود و مدل دو زبانه BERT ایجاد می گردد.

همانطور که شکل ۱۵ نشان می دهد صحت عملکرد الگوریتم BERT بر روی داده های این مقاله به زبان فارسی ۸۲ درصد است. پس از ترجیم داده ها به زبان انگلیسی با اجرای الگوریتم BERT بر روی داده ها صحت ۸۳ درصد بدست آمد که در شکل ۱۶ نمایش داده شده است.

	precision	recall	f1-score	support
0	0.80	0.72	0.76	79
1	0.84	0.89	0.86	126
accuracy			0.82	205
macro avg	0.82	0.81	0.81	205
weighted avg	0.82	0.82	0.82	205

شکل ۱۵- نمایی از خروجی الگوریتم BERT به زبان فارسی

	precision	recall	f1-score	support
0	0.81	0.73	0.77	79
1	0.84	0.89	0.86	126
accuracy			0.83	205
macro avg	0.82	0.81	0.82	205
weighted avg	0.83	0.83	0.83	205

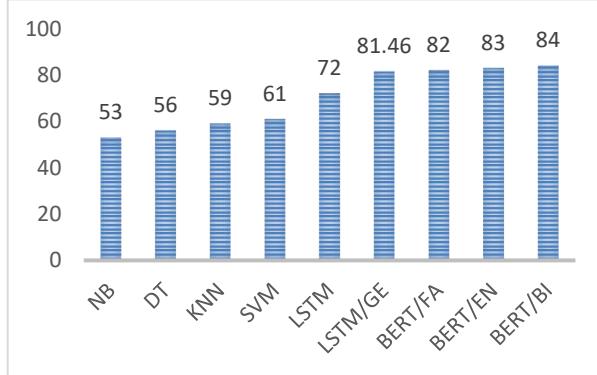
شکل ۱۶- نمایی از خروجی الگوریتم BERT به زبان انگلیسی

۳-۵- الگوریتم BERT دو زبانه

الگوریتم BERT دو زبانه یک نسخه از الگوریتم BERT است که می تواند با دو زبان مختلف کار کند. این الگوریتم می تواند متن هایی را که شامل دو زبان مختلف هستند،

۸۳	مجموع		
۸۷	ثبت	BERT	دوزبانه
۷۹	منفي		
۸۴	مجموع		

همانگونه که در شکل ۲۰ دیده می شود این مدل با صحت ۸۴ درصد عملکرد مناسبی برای تحلیل نظرات کاربران سایت سهامیاب ارائه می دهد.



شکل ۲۰- نمودار نتایج اجرا

۷- نتیجه گیری

هدف این مقاله ارائه مدلی مبتنی بر یادگیری عمیق به منظور تحلیل نظرات کاربران در خصوص سهام چند شرکت فعال بورس است که از وب سایت سهامیاب جمع آوری شده اند. تحلیل این نظرات با بهره گیری از الگوریتم های سنتی و الگوریتم های یادگیری عمیق با دو زبان فارسی و انگلیسی پیاده سازی می گردد. برای مقایسه الگوریتم های یادگیری سنتی با الگوریتم های یادگیری عمیق مدل های LSTM و BERT به زبان فارسی و BERT به زبان انگلیسی طراحی شدند. پس از پیاده سازی مدل ها، ماشین بردار پشتیبان بهترین عملکرد را در میان الگوریتم های سنتی بدست آورد و مدل های یادگیر عمیق عملکرد بهتری نسبت به الگوریتم های سنتی داشتند. در ادامه مدل LSTM باستفاده از الگوریتم فرباتکاری ژنتیک با هدف به دست آوردن هایپر پارامتر های بهینه پیاده سازی شد. با کمک الگوریتم ژنتیک این مدل نسبت به مدل اولیه LSTM پیشرفت داشت. در فاز پایانی این پژوهش الگوریتم BERT دو زبانه با ترکیب متن فارسی نظرات و معنای انگلیسی آنها پیاده سازی شد که به عملکرد ۸۴ درصد دست یافت.

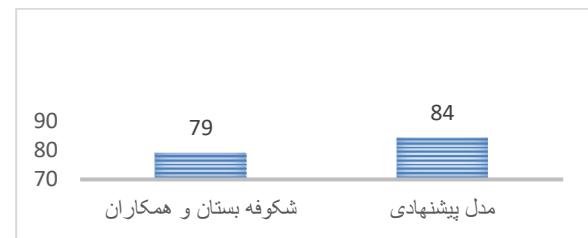
انتظار می رود این مدل عمیق چند زبانه نقش قابل توجهی در بهبود عملکرد سیستم های توصیه گر در این حوزه ایفا نماید. با توجه به اهمیت حجم دیتا در فرایند آموزش مدل های مبتنی بر شبکه های عصبی عمیق، می توان قبل از عملیات Fine-tune مدل های زبانی را بر روی حجم زیادی از دیتای بدون برچسب در این حوزه آموزش داد که کمک شایانی به درک مدل های زبانی از ادبیات حوزه مذکور خواهد نمود. بدیهی است که این امر نیازمند جمع آوری داده در حجم بالا می باشد. همچنین با افزایش دیتای برچسب زده، فرایند تشخیص احساسات بهبود خواهد یافت. علاوه بر این، در صورت فراهم نمودن منابع سخت افزاری مورد نیاز مدل های زبانی بزرگ (Large Language Models) یا به اختصار LLMs می توان از قدرت بالای یادگیری و پاسخگویی این معماری نیز بهره گرفت. یکی دیگر از کارهایی که می توان در آینده نسبت به پیاده سازی آن اقدام نمود، ایجاد یک API با هدف تحلیل احساسات Realtime و ارائه پیشنهاد برخط به معامله گران این حوزه می باشد. همچنین با توسعه این سیستم، امکان ایجاد دستیار معامله با هدف انتقال دانش و تحلیل روانشناسی در کوتاه ترین زمان ممکن فراهم خواهد آمد.

انگلیسی آنها پیاده سازی شد و به عملکرد ۸۴ درصد دست یافت. دقت حاصل از این پژوهش نسبت به کار انجام شده توسط شکوفه بستان و همکاران [۱] به عنوان مدل پایه در این مقاله در نظر گرفته شده است به میزان ۵ درصد افزایش داشته که نسبتاً قابل توجه است. جدول ۴ مقایسه دقت مدل پیشنهادی و مدل پایه (کار انجام شده توسط بستان و همکاران) را نمایش می دهد.

جدول ۴- مقایسه دقت مدل پیشنهادی با مدل پایه

مدل	مدل پیشنهادی	مدل پایه	۸۴ درصد	۷۹ درصد	چند زبانه دو کلاسه BERT

همانطور که شکل ۱۹ نشان می دهد دقت حاصل از این پژوهش نسبت به کار انجام شده توسط شکوفه بستان و همکاران ۵ درصد افزایش داشته است.



شکل ۱۹- مقایسه دقت مدل پیشنهادی و مدل پایه (کار انجام شده توسط بستان و همکاران [۱])

جدول ۵ نتایج اجرای هر کدام از این مدل ها را نشان می دهد. مشاهده می شود که مدل عمیق چند زبانه BERT بهترین عملکرد را دارد.

جدول ۵- نتایج اجرا

نوع زبان	برچسب (کلاس)	مدل	صحت
فارسی	ثبت	SVM	۶۴
فارسی	منفي		۵۰
فارسی	مجموع		۶۱
فارسی	ثبت	Decision tree	۶۶
فارسی	منفي		۴۴
فارسی	مجموع		۵۶
فارسی	ثبت	Naïve Bayes	۶۲
فارسی	منفي		۴۰
فارسی	مجموع		۵۳
فارسی	ثبت	KNN	۶۳
فارسی	منفي		۴۵
فارسی	مجموع		۵۹
فارسی	ثبت	LSTM	۷۶
فارسی	منفي		۶۵
فارسی	مجموع		۷۲
فارسی	ثبت	Genetic + LSTM	۸۴
فارسی	منفي		۷۳
انگلیسی	مجموع		۸۱/۴۶
فارسی	ثبت	BERT	۸۴
فارسی	منفي		۸۰
انگلیسی	مجموع		۸۲
انگلیسی	ثبت	BERT	۸۴
انگلیسی	منفي		۸۱

۸- مراجع

- [۱] استان شکوفه، زارع بیدکی علی محمد، پژوهان محمدرضا، "دون سازی معنایی واژه ها با استفاده از BERT روی وب فارسی"، مهندسی برق و مهندسی کامپیوتر ایران - ب مهندسی کامپیوتر، شماره ۲، دوره ۲۱، شماره: ۲، صفحات ۸۹-۱۰۰، ۱۴۰۲.
- [۲] Antonakaki, D., Fragopoulou, P., & Ioannidis, S., A survey of Twitter research: Data model, graph structure, sentiment analysis and attacks. *Expert Systems with Applications*, 164, 114006, 2021.
- [۳] Basiri, M. E., Nemati, S., Abdar, M., Cambria, E., & Acharya, U. R., ABCDM: An attention-based bidirectional CNN-RNN deep model for sentiment analysis, *Future Generation Computer Systems*, 115, 279-294, 2021.
- [۴] Dashtipour, K., Gogate, M., Cambria, E., & Hussain, A., A novel context-aware multimodal framework for persian sentiment analysis, *Neurocomputing*, 457, 377-388, 2021.
- [۵] Eck, M., Germani, J., Sharma, N., Seitz, J., & Ramdasi, P. P., Prediction of stock market performance based on financial news articles and their classification, *Data Management, Analytics and Innovation*, vol 1175, pp. 35-44, 2020.
- [۶] Hong, S., A study on stock price prediction system based on text mining method using LSTM and stock market news, *Journal of Digital Convergence*, 18(7), 223-228, 2020.
- [۷] Li, H., Chen, Q., Zhong, Z., Gong, R., & Han, G., E-word of mouth sentiment analysis for user behavior studies, *Information Processing & Management*, 59(1), 102784, 2020.
- [۸] Li, Y., & Pan, Y., A novel ensemble deep learning model for stock prediction based on stock prices and news, *International Journal of Data Science and Analytics*, Volume 13, pages 139-149, 2021.
- [۹] Liu, B., Sentiment analysis: Mining opinions, sentiments, and emotions, *Cambridge university press*, 2020.
- [۱۰] Lutz, B., Pröllochs, N., & Neumann, D., Predicting sentence-level polarity labels of financial news using abnormal stock returns, *Expert Systems with Applications*, 148, 113223, 2020.
- [۱۱] Man, R., & Lin, K., Sentiment analysis algorithm based on BERT and convolutional neural network, In 2021 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC) (pp. 769-772). IEEE, 2021.
- [۱۲] Mate, G. S., Kulkarni, R., Amidwar, S., & Muthya, Stock prediction through news sentiment analysis, *Journal of Architecture & Technology*, 11(8). 36-40, 2020.
- [۱۳] Mitra, A., Sentiment analysis using machine learning approaches (Lexicon based on movie review dataset), *Journal of Ubiquitous Computing and Communication Technologies (UCCT)*, 2(03), 145-152, 2020.
- [۱۴] Nemati, S., Rohani, R., Basiri, M. E., Abdar, M., Yen, N. Y., & Makarenkov, V., A hybrid latent space data fusion method for multimodal emotion recognition, *IEEE Access*, 7, 172948-172964, 2019.
- [۱۵] Sadr, H., Pedram, M. M., & Teshnehab, M., Multi-view deep network: a deep model based on learning features from heterogeneous neural networks for sentiment analysis, *IEEE access*, 8, 86984-86997, 2020.
- [۱۶] Sallam, R. M., Hussein, M., & Mousa, H. M., Improving collaborative filtering using lexicon-based sentiment analysis, *International Journal of Electrical and Computer Engineering*, 12(2), 1744, 2022.
- [۱۷] Shah, A. M., Yan, X., Shah, S. A. A., & Mamirkulova, G. Mining patient opinion to evaluate the service quality in healthcare: a deep-learning approach, *Journal of Ambient Intelligence and Humanized Computing*, 11(7), 2925-2942, 2020.
- [۱۸] Shah, P., Swaminarayan, P., & Patel, M., Sentiment analysis on film review in Gujarati language using machine learning, *International Journal of Electrical and Computer Engineering*, 12(1), 1030, 2022.