Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
DOI: 10.22034/jscit.2025.493690.2081
Volume 14, Number 3, Autumn 2025, pp. 11-12
Received: 12/13/2024, Revised: 07/02/2025, Accepted: 07/28/2025

Predicting Airline Passenger Satisfaction Using Hybrid Neural Networks

Saeed Dadgar [1], Zoleikha Jahanbakhsh Nagadeh[2*]
1- Department of Computer Engineering, ST.C., Islamic Azad University, Tehran, Iran.
2*- Department of Computer Engineering, Nag.C., Islamic Azad University, Naghadeh, Iran.
[1] s.dadgar@iau.ir, [2*]zoleikha.jahanbakhsh@iau.ac.ir

Corresponding author's address: Zoleikha Jahanbakhsh Nagadeh, Tehran, Deh Haqi Street (Ahang) - at the corner of Kowsar Boulevard, Department of Computer Engineering, ST.C., Islamic Azad University, Tehran, Iran.

Abstract- After the COVID-19 pandemic, the aviation industry faced significant challenges, including a sharp decline in the number of passengers. As conditions returned to normal, improving service quality to enhance passenger satisfaction and loyalty became increasingly important. In this regard, leveraging advanced technologies and deep learning can play a crucial role in predicting passenger satisfaction and optimizing services. In this study, a hybrid model based on Bidirectional Long Short-Term Memory (BiLSTM), Convolutional Neural Network (CNN), and an Attention Mechanism is proposed to predict passenger satisfaction. BiLSTM is employed for processing textual data and capturing long-term dependencies, the attention mechanism is utilized to focus on important features while ignoring less relevant information, and CNN is used to extract key features from the data. In the proposed model, the output of BiLSTM, enhanced by the attention mechanism, is combined with CNN to improve prediction accuracy. This combination enables the simultaneous utilization of BiLSTM's ability to process sequential data along with attention weighting and CNN's capability to extract local features, ultimately enhancing the accuracy and performance of passenger satisfaction prediction. The dataset used consists of 129,880 passenger reviews and includes 24 key features. The final label in this dataset classifies passenger satisfaction into two categories: "satisfied" and "dissatisfied." Experimental results show that the combination of these three components (BiLSTM + CNN + Attention) achieved 99.75% accuracy, 99.97% recall, and 99.86% F1-score, demonstrating the superior performance of the proposed model in predicting passenger satisfaction. Therefore, this model can significantly assist airlines in improving service quality and increasing passenger loyalty.

Keywords- Airline industry, airlines, passenger satisfaction, BiLSTM, convolutional neural network, passenger loyalty.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
شناسه دیجیتال: 10.22034/jscit.2025.493690.2081
جلد ۱۴، شماره ۳، پاییز ۱۴۰۴ صفحه ۱-۱۲
دریافت: ۱۴۰۳/۰۹/۲۳، بازنگری: ۱۴۰۴/۰۴/۱۱، پذیرش: ۱۴۰۴/۰۵/۰۶

پیش‌بینی رضایتمندی مسافران خطوط هوایی با استفاده از شبکه‌های عصبی ترکیبی

سعید دادگر[۱]، زلیخا جهانبخش نقده *[۲]
۱- دانشکده مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران.
*۲- گروه مهندسی کامپیوتر، واحد نقده، دانشگاه آزاد اسلامی، نقده، ایران.
[1]s.dadgar@iau.ir, [2*]zoleikha.jahanbakhsh@iau.ac.ir

* نشانی نویسنده مسئول: زلیخا جهانبخش نقده، تهران، خیابان ده حقی (آهنگ) - نبش بلوارکوثر.، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران.

چکیده- صنعت هوایی یکی از مهم‌ترین صنایع جهان است که پس از شیوع COVID-19 با تغییرات چشمگیری مواجه شد. کاهش شدید تعداد مسافران چالش‌های جدی را برای شرکت‌های هواپیمایی ایجاد کرد و با بهبود شرایط، ضرورت ارائه خدمات باکیفیت برای افزایش رضایتمندی و وفاداری مسافران اهمیت بیشتری یافت. در این راستا، بهره‌گیری از فناوری‌های نوین و یادگیری عمیق می‌تواند نقش مؤثری در پیش‌بینی میزان رضایت مسافران و بهینه‌سازی خدمات ایفا کند. در این پژوهش، یک مدل ترکیبی مبتنی بر شبکه‌های حافظه بلند-کوتاه مدت دوطرفه (BiLSTM) ، شبکه عصبی پیچشی (CNN) همراه با مکانیزم توجه برای پیش‌بینی میزان رضایتمندی مسافران ارائه شده است. BiLSTM برای پردازش داده‌های متنی و درک وابستگی‌های زمانی طولانی‌مدت مکانیزم توجه برای تمرکز بر ویژگی‌های مهم و نادیده‌گیری اطلاعات کم‌اهمیت و CNN برای استخراج ویژگی‌های کلیدی از داده‌ها به کار گرفته شده‌اند. در مدل پیشنهادی خروجی BiLSTM همراه با مکانیزم توجه با CNN ترکیب می شوند. این ترکیب موجب بهره‌گیری همزمان از توانایی‌های پردازش توالی‌های زمانی(BiLSTM) به همراه اعمال مکانیزم توجه و همچنین استخراج ویژگی‌های محلی (CNN) شده و دقت و عملکرد مدل را در پیش‌بینی رضایتمندی مسافران بهبود داده است. مجموعه داده مورد استفاده شامل ۱۲۹۸۸۰ نمونه از نظرات مسافران بوده و شامل ۲۴ ویژگی است. برچسب نهایی این داده‌ها میزان رضایتمندی مسافران را با دو مقدار "راضی" و "ناراضی" مشخص می‌کند. نتایج آزمایش‌ها نشان می‌دهد که ترکیب این سه بخش (BiLSTM + CNN + Attention) با دقت ۹۹/۷۵٪، یادآوری ۹۹/۹۷٪ و معیار F1، ۹۹/۸۶ ٪ بهترین عملکرد را در پیش‌بینی رضایتمندی مسافران ارائه داده است، بنابراین، مدل پیشنهادی می‌تواند به شرکت‌های هواپیمایی در بهبود کیفیت خدمات و افزایش وفاداری مسافران کمک شایانی کند.

واژه‌های کلیدی: صنعت هوایی، شرکت‌های هواپیمایی، **BiLSTM**، رضایتمندی مسافران، شبکه عصبی پیچشی، وفاداری مسافران.

۱- مقدمه

با توجه به گسترش مرزهای جغرافیایی میان کشورهای دنیا و همچنین روند رشد جمعیت، یکی از عوامل مهم اقتصادی در دنیا بحث ارتباطات و ارائه خدمات است. صنعت خدمات به‌عنوان یکی از عوامل موثر در زمینه مسایل اقتصادی مطرح است. امروزه صنعت خدمات به مهمترین بخش اقتصاد جهان تبدیل شده است [۱]. در ایالات متحده، صنعت خدمات حدود ۶۰ درصد از تولید ناخالص داخلی و نزدیک به ۷۰ درصد از مشاغل را شامل می‌گردد که این

آمار بیانگر اهمیت صنایع خدماتی در سراسر جهان است [۲]. شرکت‌ها بدنبال ارائه خدمات بهتر و پایدارتر به لحاظ سرویس‌های به‌روز و پشتیبانی آنلاین به مشتریان خود هستند. امروزه رقابت در ارائه خدمات و پشتیبانی به‌منظور جذب مشتری بیشتر میان شرکت‌های خدماتی بیش از گذشته به چشم می‌آید. در این میان، صنعت هوایی به‌عنوان یکی از حیاتی‌ترین صنایع حمل‌ونقل، نقش بزرگی در جابجایی میلیون‌ها مسافر به‌صورت روزانه ایفا می‌کند. با توجه به افزایش روزافزون تعداد مسافران و پیشرفت‌های فناوری، کیفیت خدمات ارائه‌شده توسط خطوط هوایی تأثیر مستقیمی بر رضایتمندی و وفاداری مسافران دارد. پس از همه‌گیری COVID-19، تغییرات عمده‌ای در انتظارات مسافران از خدمات هوایی ایجاد شد و شرکت‌های هواپیمایی به‌دنبال راهکارهای نوین برای بهبود تجربه مشتریان خود هستند. یکی از چالش‌های اساسی در این صنعت، پیش‌بینی رضایتمندی مسافران بر اساس داده‌های واقعی و تحلیل احساسات آن‌ها از خدمات ارائه‌شده است[۳ و۴].

پیش‌بینی دقیق میزان رضایت مسافران می‌تواند به شرکت‌های هواپیمایی در بهینه‌سازی خدمات، افزایش وفاداری مشتریان و در نهایت، بهبود درآمد کمک کند. روش‌های سنتی ارزیابی رضایتمندی معمولاً بر اساس نظرسنجی‌های دستی و تحلیل‌های آماری انجام می‌شوند که به دلیل حجم بالای داده‌ها و پیچیدگی‌های ذاتی احساسات مسافران، کارایی محدودی دارند. در این راستا، الگوریتم‌های یادگیری عمیق توانایی بالایی در استخراج ویژگی‌های مهم از داده‌های متنی و عددی دارند و می‌توانند برای بهبود دقت پیش‌بینی استفاده شوند. با این حال، چالش اصلی این است که چه ترکیبی از این روش‌ها بهترین عملکرد را در پیش‌بینی رضایتمندی مسافران خواهد داشت.

در این پژوهش، یک مدل ترکیبی مبتنی بر شبکه عصبی پیچشی[۱](CNN) ، حافظه بلند-کوتاه‌مدت دوطرفه[۲] (BiLSTM) و اعمال مکانیزم توجه[۳] ارائه شده است. مدل پیشنهادی قادر است وابستگی‌های طولانی‌مدت را در داده‌های متنی درک کرده و بر اطلاعات مهم‌تر تمرکز کند. مکانیزم توجه به مدل این امکان را می‌دهد که ویژگی‌های کلیدی موجود در نظرات مسافران را برجسته کرده و دقت پیش‌بینی را افزایش دهد. استفاده از این مدل ترکیبی، عملکرد بهتری را نسبت به روش‌های یادگیری عمیق منفرد ارائه می‌دهد.

ضرورت این تحقیق ناشی از نیاز به مدل‌هایی است که علاوه بر دقت بالا، از نظر محاسباتی نیز کارآمد باشند و بتوانند داده‌های حجیم را با کمترین میزان پیچیدگی پردازش کنند. انتظار می‌رود که مدل پیشنهادی بتواند دقت، یادآوری و معیار F1 را نسبت به مدل‌های پیشین بهبود بخشد و به‌عنوان یک راهکار کارآمد برای پردازش داده‌های متنی در حوزه‌های مختلف ازجمله تحلیل احساسات، دسته‌بندی متون و سیستم‌های پیشنهاد دهنده مورد استفاده قرار گیرد.

ساختار مقاله به این صورت است که در بخش دوم، مروری بر تحقیقات پیشین ارائه شده است. در بخش سوم، روش‌شناسی و مدل پیشنهادی توضیح داده می‌شود. بخش چهارم به ارائه نتایج آزمایش‌ها و تحلیل آن‌ها اختصاص دارد و در نهایت، در بخش پنجم، نتیجه‌گیری و پیشنهادهای آینده مطرح شده است.

۲- پژوهش‌های پیشین

نظر به اهمیت موضوع در رابطه با پژوهش انجام شده، مطالعات متعددی به بررسی و پیش‌بینی رضایتمندی مشتریان در صنعت هوایی پرداخته‌اند. این مطالعات را می‌توان به سه دسته اصلی تقسیم کرد: ۱) روش‌های سنتی مبتنی بر تحلیل آماری. ۲) روش‌های یادگیری ماشین و ۳) روش‌های یادگیری عمیق.

۲-۱- روش‌های مبتنی بر تحلیل آماری

چندین پژوهش به بررسی عوامل مؤثر بر رضایتمندی مسافران پرداخته‌اند. برای مثال، چن [۴] نشان داد که کیفیت خدمات، ارزش درک‌شده و قیمت، نقش مهمی در میزان رضایت و وفاداری مشتریان دارند. تیرنن و همکاران [۶] نیز رابطه میان کیفیت خدمات و رضایتمندی مسافران را تحلیل کردند و دریافتند که عوامل فیزیکی مانند راحتی صندلی، زمان انتظار و کیفیت غذا بر تجربه مسافران تأثیرگذار است. این روش‌ها اگرچه اطلاعات مهمی ارائه می‌دهند، اما به دلیل حجم بالای داده‌ها و تغییرات سریع در صنعت هوایی، قابلیت تطبیق‌پذیری محدودی دارند.

۲-۲- روش‌های مبتنی بر یادگیری ماشین

با پیشرفت تکنیک‌های یادگیری ماشین، روش‌هایی مانند جنگل تصادفی[۴]، ماشین بردار پشتیبان[۵] (SVM) و XGBoost برای پیش‌بینی رضایتمندی مسافران مورد استفاده قرار گرفته‌اند.

هونگ و همکاران[۷] با استفاده از مدل جنگل تصادفی بر روی مجموعه داده‌ای شامل ۱۲۹۸۸۰ ورودی، بهترین نتایج را در مقایسه با سایر الگوریتم‌ها برای پیش‌بینی رضایتمندی مسافران خطوط هوایی کسب کردند.

نوردینا و همکاران[۸] در مقاله‌ای تحت عنوان مقایسه بررسی دسته بندی مسافران هوایی، الگوریتم نایو بیز[۶] را با نزدیک‌ترین همسایه (KNN) مقایسه کردند و دریافتند که نایو بیز دقت بیشتری دارد.

هایادی و همکاران[۹] طی مقاله‌ای با عنوان پیش‌بینی رضایتمندی مسافران هوایی با استفاده از الگوریتم‌های طبقه‌بندی به بررسی موضوع رضایتمندی مسافران پرداختند. در این مقاله تعداد ویژگی‌ها از ۲۳ به ۱۸ تقلیل داده شده و همچنین تقسیم‌بندی داده‌یِ آموزش و آزمایش بصورت ۸۰ به ۲۰ بوده است . این مطلب بیانگر این است که فضای بیشتری برای آموزش مدل در نظر گرفته شده است. مجموعه‌داده مورد استفاده در این مقاله همان مجموعه‌داده مربوط به مسافران خطوط هوایی با ۱۲۹۸۸۰ ورودی می باشد.

پریرا و همکاران[۱۰] نیز در مقاله ای تحت عنوان تاثیر بیماری COVID-19 بر رضایتمندی مسافران هوایی به این موضوع پرداخته اند. آنها از سه الگوریتم ماشین بردار پشتیبان (SVM)، رگرسیون لجستیک[۷](LR) و همچنین درخت تصمیم به منظور پیش بینی رضایتمندی مسافران استفاده شده که نهایتا بهترین مقدار توسط آموزش مدل با استفاده از الگوریتم SVM اعلام گردیده است.

دایک و همکاران[۱۱] مقاله ای تحقیقاتی به صورت آنلاین با عنوان ارزیابی انتظارات مسافران صنعت هوایی منتشر کردند. در پژوهش فوق نظرات ۱۷۷۲۶ مسافر در وب‌سایت Skytrax[۸] مورد بررسی قرار گرفته که کمترین میزان رضایت برای مسافران کشورهای آمریکا، کانادا و هندوستان در رابطه با دو ویژگی تاخیر در پرواز و مدیریت بار مسافران بدست آمده است. این دو ویژگی در مقاله حال حاضر نیز به عنوان عوامل تاثیرگذار در پارامترهای دقت مدل نیز لحاظ شده‌اند.

میردیپاتی و همکاران[۱۲]مقاله ای با عنوان افزایش رضایت مسافران خطوط هوایی منتشر کردند. نویسندگان با استفاده از الگوریتم‌های یادگیری ماشین SVM، درخت تصمیم[۹]، جنگل تصادفی، KNN، Gradient Boosting و رگرسیون منطقی[۱۰] میزان رضایتمندی مسافران را پیش‌بینی کردند. آنها ارزیابی‌هایشان را بر روی مجموعه داده‌ای حاوی اطلاعات ۱۰۰۰۰۰مسافر با تعداد ۲۲ ویژگی انجام دادند[۱۱] بهترین نتیجه بدست‌آمده برای الگوریتم‌های یادگیری SVM و Gradient Boosting بوده است.

ابراهیم و همکاران[۱۳] مقاله ای با عنوان تجزیه و تحلیل رضایت مسافران خطوط هوایی با تکنیک‌های یادگیری ماشین منتشر نمودند. در این مقاله از چهار الگوریتم SVM، جنگل تصادفی، درخت تصمیم و XGBoost استفاده گردیده که بهترین عملکرد مربوط به مدل XGBoost بوده است.

شاهید و همکاران[۱۴] مقاله‌ای تحت عنوان پیش بینی وفاداری مسافران در صنعت هوایی که بر روی بیش از ۱۷۰۰۰ مسافر مطالعه شده بود منتشر کردند.در این تحقیق از سه الگوریتم جنگل تصادفی، درخت تصمیم و XGBoost استفاده گردیده که بیشترین میزان دقت در مدل XGBoost بدست آمد.

۲-۳- روش‌های مبتنی بر یادگیری عمیق

در حوزه پیش‌بینی رضایت مسافران، مطالعات متعددی با استفاده از الگوریتم‌های یادگیری عمیق انجام شده است. در ادامه، به چند نمونه از این پژوهش‌ها اشاره شده است.

لیاناگ و همکاران [۱۶] مدل‌های LSTM و BiLSTM را برای پیش‌بینی تقاضای مسافران اتوبوس توسعه دادند. نتایج آنها نشان داد که مدل BiLSTM با دقت بیش از ۹۰٪ عملکرد بهتری نسبت به سایر مدل‌های آزمایش‌شده داشت. تمرکز اصلی نویسندگان بر پیش‌بینی تقاضای مسافران بوده و به‌طور مستقیم به رضایت مسافران نپرداخته است.

پرنیان [۱۷] ، با ترکیب شبکه‌های CNN و BiLSTM، نظرات مشتریان را تحلیل و طبقه‌بندی کرد. پس از ۹۰ دوره آموزش، مدل به دقت ۹۳٪ دست‌یافت. در این مدل از مکانیزم توجه برای تمرکز بر ویژگی‌های مهم در داده‌ها استفاده نشده است. همچنین، عدم ترکیب مناسب ویژگی‌های استخراج‌شده توسط CNN و BiLSTM برای بهبود دقت پیش‌بینی صورت نگرفته است.

سو هیون پارک و همکاران [۱۸] از مدل CNN-LSTM برای تحلیل نظرات مسافران خطوط هوایی کره جنوبی استفاده کردند و به دقت ۹۰٪ رسیدند، اما این مدل در پردازش جملات طولانی و مدیریت وابستگی‌های طولانی‌مدت دچار چالش بود.

شیما اوف [۱۹] ، مدل شبکه‌های عصبی مصنوعی (ANN) را با الگوریتم‌های یادگیری ماشین (از جمله جنگل تصادفی و ماشین بردار پشتیبان) مقایسه کرد و دقت ۹۹,۳٪ را گزارش کرد. البته این دقت در نتیجه تقسیم داده‌ها به ۹۰٪ جهت آموزش و ۱۰٪ جهت تست که بیانگر آموزش بیشتر مدل می باشد و همچنین تعداد ۲۰۰ دوره آموزش (epochs) و استفاده از ۳ لایه پنهان با Batch size=2500 ، به دست آمده است. البته با وجود استفاده ازتنظیمات هایپر پارامترها که به آن اشاره شده است و عدم رعایت استاندارد جداسازی داده‌های آموزش و تست ، عدم استفاده از مکانیزم توجه و همچنین عدم ترکیب مدلهای یادگیری عمیق و استفاده از مدل تک‌ساختاری، کماکان دقت نویسندگان کمتر از دقت مدل پیشنهادی این پژوهش است.

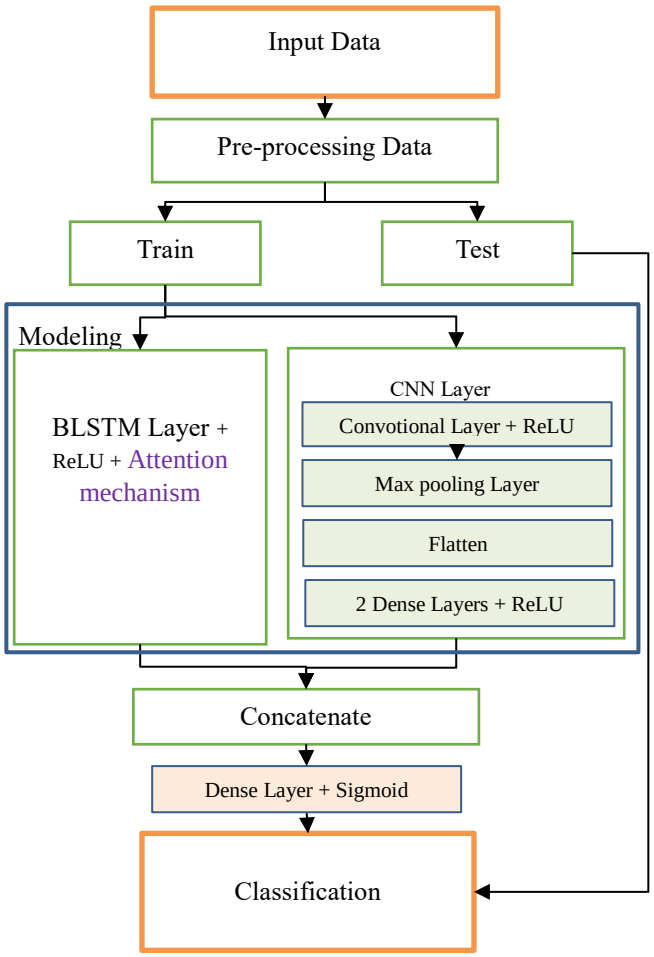
۲-۴- مزایا و معایب روش‌های پیشین و مزیت روش پیشنهادی

مدل‌های مبتنی بر LSTM و GRU قابلیت حفظ وابستگی‌های طولانی‌مدت در متن و پردازش داده‌های ترتیبی را دارند. مدل‌های مبتنی‌بر CNN دارای قابلیت بالا در استخراج ویژگی‌های محلی و یافتن الگوهای کلیدی در متن می‌باشند. الگوریتم‌های XGBoost و Random Forest: عملکرد بالا در پردازش داده‌های ساختاریافته و ارائه نتایج دقیق دارند. مدل‌های ترکیبی CNN-LSTM و BiLSTM در مقایسه با مدل‌های تکی عملکرد بهتری دارند.

از معایب این روش‌ها می‌توانیم به این مورد اشاره کنیم که ، مدل-های مبتنی‌بر LSTM و GRU مشکل از بین رفتن گرادیان و کاهش دقت در پردازش جملات طولانی را دارند. مدل‌های مبتنی بر CNN در حفظ وابستگی‌های طولانی‌مدت و تحلیل عمیق ساختار متن توانایی ندارند. روش‌های سنتی یادگیری ماشین از جمله SVM، Random Forest، XGBoost وابسته به ویژگی‌های استخراج‌شده به‌صورت دستی دارند و نیازمند به فرآیند بهینه‌سازی هستند. در مدل ترکیبی BiLSTM-CNN، فاقد مکانیزم‌هایی برای تمرکز بر ویژگی‌های مهم‌تر متن، و مستعد کاهش دقت در جملات طولانی و پیچیده می‌باشند.

در پژوهش حاضر، یک مدل ترکیبی شامل BiLSTM، CNN و مکانیزم توجه پیشنهاد شده است که معایب روش‌های پیشین را برطرف می‌کند. به این صورت که، BiLSTM برای حفظ وابستگی‌های طولانی‌مدت و پردازش داده‌های متنی دوطرفه استفاده شده است. مکانیزم توجه برای تمرکز بر بخش‌های کلیدی متن و کاهش تأثیر اطلاعات غیرضروری به‌کارگرفته شده است. CNN برای استخراج ویژگی‌های محلی و ترکیب اطلاعات در سطوح مختلف پردازش استفاده شده است. درنتیجه دقت مدل در تحلیل داده‌های متنی افزایش می‌یابد. انتظار می‌رود که این روش نسبت به رویکردهای قبلی عملکرد بهتری ارائه دهد و بتواند وابستگی‌های طولانی‌مدت و ویژگی‌های محلی را هم‌زمان در نظر بگیرد.

مرور پژوهش‌های پیشین نشان می‌دهد که روش‌های سنتی تحلیل آماری تطبیق‌پذیری محدودی دارند، روش‌های یادگیری ماشین به ویژگی‌های دستی وابسته‌اند، و روش‌های یادگیری عمیق در مدیریت اطلاعات مهم متن دچار محدودیت هستند. مدل پیشنهادی با ترکیب BiLSTM، CNN و مکانیزم توجه، مزایای روش‌های قبلی را حفظ کرده و معایب آن‌ها را کاهش داده است. این مدل قابلیت بهبود عملکرد در تحلیل داده‌های متنی، افزایش دقت و کاهش نرخ خطاهای طبقه‌بندی را داراست و می‌تواند در حوزه‌های مختلف از جمله تحلیل احساسات و سیستم‌های پیشنهاددهنده مورد استفاده قرار گیرد.



شکل۱- بلوک دیاگرام روش پیشنهادی

۳- روش پیشنهادی

در این پژوهش، یک مدل ترکیبی مبتنی‌بر شبکه‌های حافظه بلند-کوتاه‌مدت دوطرفه (BiLSTM) و شبکه عصبی پیچشی (CNN) همراه با مکانیزم توجه برای پیش‌بینی میزان رضایتمندی مسافران ارائه شده است. این مدل با هدف رفع چالش‌های مربوط به وابستگی‌های طولانی‌مدت، استخراج ویژگی‌های کلیدی و تمرکز بر اطلاعات مهم متن طراحی شده است. این مدل به‌گونه‌ای طراحی شده که با استفاده BiLSTM قادر به درک روابط طولانی‌مدت بین کلمات و درک دقیق‌تر زمینه زبانی است، درحالی‌که CNN قابلیت استخراج ویژگی‌های کلیدی از داده‌های متنی را دارد و می‌تواند ویژگی‌های کلیدی موجود در داده‌های متنی را استخراج کرده و با بهره‌گیری از مکانیزم توجه، تمرکز بیشتری بر اطلاعات مهم‌تر داشته باشد. همچنین. دلیل دیگر برای ترکیب دو معماری یادگیری عمیق BiLSTM و CNN ، بهبود تحلیل داده‌های متنی و عددی به‌صورت هم‌زمان می‌باشد. بلوک دیاگرام مدل پیشنهادی در شکل ۱ نمایش

داده شده است. در ادامه، جزئیات هر یک از اجزای مدل توضیح داده شده است.

- لایه ورودی: داده‌های متنی با استفاده از تعبیه سازی کلمه[۱۲] به بردارهای عددی تبدیل می‌شوند و به BiLSTM وارد می‌شوند.
- لایه‌یBiLSTM : این لایه به تحلیل وابستگی‌های معنایی متون کمک می‌نماید. BiLSTMبه‌دلیل ساختار دوطرفه خود، برخلاف LSTM معمولی، توانایی بیشتری در تحلیل ترتیب زمانی نظرات مسافران دارد و اطلاعات متنی را از دو جهت پردازش می‌کند.
- مکانیزم توجه: پس از خروجیBiLSTM ، مکانیزم توجه اعمال می‌شود تا مهم‌ترین کلمات در جمله شناسایی شده و وزن بیشتری به آن‌ها اختصاص داده شود. این مکانیزم نقش مهمی در وزن دهی به اطلاعات مفید را در مجموعه داده به عهده دارد. هدف از توسعه‌ی مکانیزم توجه در یادگیری عمیق آن است که به مدل کمک کند تا بر روی مرتبط‌ترین بخش‌های ورودی تمرکز کند و عملکرد بهتری در درک روابط پیچیده بین کلمات داشته باشد. در نتیجه دقت پیش‌بینی نهایی مدل بیشتر می‌گردد.
- لایه‌ی CNN: CNN به‌عنوان یک مدل مؤثر در پردازش داده‌های ترتیبی، امکان شناسایی الگوهای مهم را از نظرات متنی دارد و باعث کاهش پیچیدگی محاسباتی مدل می‌شود. در این لایه از یک لایه MaxPooling برای کاهش ابعاد و حفظ ویژگی‌های مهم، یک لایه Flatten برای تبدیل ویژگی‌های استخراج‌شده به یک بردار تک‌بعدی جهت پردازش در لایه‌های کاملاً متصل، دو لایه Dense کاملاً متصل با ۶۴ نورون و تابع فعال‌سازی ReLU برای یادگیری ویژگی‌های سطح بالا استفاده شده است.
- ترکیب[۱۳] BiLSTM و CNN: ترکیب خروجی این دو مدل باعث افزایش دقت پیش‌بینی می‌شود زیرا BiLSTM با پردازش اطلاعات توالی‌دار، جزئیات معنایی را استخراج می‌کند، و CNN به‌صورت مؤثر ویژگی‌های مهم را از داده‌ها فشرده‌سازی و استخراج می‌کند. این ترکیب باعث افزایش توانایی مدل در تحلیل داده‌های حجیم و بهبود دقت نهایی پیش‌بینی می‌شود.
- لایه‌هایFully Connected: ترکیب BiLSTM و CNN به لایه‌های متراکم[۱۴] متصل شده و پس از اعمال تابع فعال‌سازی Sigmoid، نتیجه نهایی به‌دست می‌آید.
- بهینه‌سازی و آموزش: مدل با استفاده از Adam Optimizer و تابع هزینه Cross-Entropy آموزش داده شده است.

این ساختار به مدل اجازه می‌دهد تا هم ویژگی‌های مکانی CNN و هم ویژگی‌های زمانی BiLSTM را به‌طور هم‌زمان تحلیل کرده و با و تمرکز بر اطلاعات مهم متن دقت پیش‌بینی را افزایش دهد.

۳-۱- مجموعه داده

در این پژوهش، داده‌های بروزرسانی شده مربوط به نظرسنجی مسافران خطوط هوایی بکار گرفته شده در مقاله میردیپاتی و همکاران[۱۲] برای پیش‌بینی رضایتمندی مسافران خطوط هوایی مورد تحلیل قرار گرفته است. این مجموعه داده شامل ۱۲۹۸۸۰ ورودی نظرسنجی است که اطلاعاتی مانند ویژگی‌های پرواز و مشخصات مسافران را شامل می‌شود. این داده شامل ۲۴ ویژگی (مانند نحوه تهیه بلیط، راحتی صندلی، رفتار مهمانداران، میزان تأخیر، کیفیت سرویس‌های آنلاین، کیفیت خدمات، فرآیند رزرو بلیط آنلاین، محل تحویل بار، کلاس‌پرواز، کیفیت غذا و نوشیدنی و ...) و یک ستون هدف (سطح رضایتمندی مسافران) می‌باشد که میزان رضایتمندی مسافران را با دو مقدار "راضی" و "ناراضی" مشخص می‌نماید. این مجموعه داده از سایت Kaggle.com استخراج گردیده است.

۳-۲- پیش‌پردازش داده‌ها

قبل از اعمال مدل‌های یادگیری عمیق، داده‌های اولیه مورد پاکسازی و پیش‌پردازش قرار گرفتند. این مرحله شامل شناسایی و جایگزینی مقادیر گمشده(NaN)[۱۵] ، نرمال‌سازی داده‌ها برای توزیع یکنواخت‌تر داده‌ها و بهبود عملکرد مدل می‌باشد. پس از انجام این مراحل، داده‌ها به شکلی مناسب برای آموزش مدل‌ها آماده شدند. نهایتا، تقسیم‌بندی داده‌ها به مجموعه‌های آموزش (۷۰٪) و آزمایش (۳۰٪) انجام شده است. بخش آموزش را هم مجدداً به دو قسمت با نسبت ۷۰٪ به ۳۰٪ تقسیم نموده که ۳۰٪ آن را برای ارزیابی یا validation در نظر گرفتیم.

۳-۳- معرفی مدل های مورد استفاده

در این پژوهش، دو مدل مختلف یادگیری عمیق شامل حافظه بلند-کوتاه‌مدت دوطرفه (BiLSTM)، و شبکه عصبی پیچشی (CNN) به‌صورت مجزا مورد ارزیابی قرار گرفتند.

۳-۳-۱- مدل حافظه کوتاه-بلند مدت دو طرفه (BLSTM)

شبکه‌های عصبی بازگشتی دوطرفه انواعی از شبکه‌های عصبی بازگشتی هستند که دو لایه پنهان در دو جهت مختلف در یک شبکه عصبی را به‌یک خروجی یکسان وصل می‌کند. این رویکرد یکی از رویکردهای مدل‌های یادگیری عمیق سازنده است که به این ترتیب خروجی می‌تواند اطلاعات را هم از گذشته و هم از آینده به صورت همزمان دریافت کند. این مدل برای افزایش حجم اطلاعات ورودی به شبکه‌های عصبی ابداع شدند. به عنوان نمونه مدل‌های پیشین نظیر مدل پرسپترون چند لایه[۱۶] و شبکه عصبی با تأخیر زمانی[۱۷] محدودیت‌هایی روی انعطاف‌پذیری دیتای ورودی دارند چراکه باید داده ورودی آنها به صورت ثابت باشد. از طرفی شبکه‌های عصبی بازگشتی استاندارد نیز محدودیت‌هایی دارند چراکه نمی‌توانند داده را از آینده دریافت نمایند. حال، راهکار تمامی این مشکلات استفاده از شبکه‌های عصبی بازگشتی دوطرفه است که هیچ یک از محدودیت‌های فوق را ندارند. به عبارتی هم لازم نیست داده ورودی آنها ثابت باشد و هم می‌توانند از هر حالتی گذشته و آینده را به صورت همزمان ببینند و اطلاعات بیشتری برای یادگیری مدل استفاده نمایند[۱۵].

۳-۳-۲- مدل شبکه عصبی پیچشی (CNN)

یک شبکه عصبی پیچشی از یک لایه ورودی، یک لایه خروجی و تعدادی لایه پنهان تشکیل شده است. لایه‌های پنهان یا پیچشی هستند، یا تجمعی یا کامل. لایه‌های پیچشی یک عمل پیچش را روی ورودی اعمال می‌کنند، سپس نتیجه را به لایه بعدی می‌دهند. هر نورون پیچشی داده‌ها را تنها برای ناحیه پذیرش خودش پردازش می‌کند. مشبک‌کردن به شبکه‌های پیچشی این اجازه را می‌دهد که انتقال، دوران یا اعوجاج ورودی را تصحیح کنند.

شبکه‌های عصبی پیچشی مشابه سیستم پردازش دیداری در موجودات زنده عمل می‌کنند. به عبارتی شبکه عصبی پیچشی نوعی شبکه عصبی مصنوعی است. این شبکه شامل لایه‌های کانولوشن برای استخراج ویژگی‌هاست. از قرن نوزدهم به‌طور همزمان اما جداگانه از سویی نوروفیزیولوژیست‌ها سعی کردند سیستم یادگیری و تجزیه و تحلیل مغز را کشف کنند و از سوی دیگر ریاضیدانان تلاش کردند مدل ریاضی‌ای بسازند که قابلیت فراگیری و تجزیه و تحلیل عمومی مسائل را دارا باشد. اولین کوشش‌ها در شبیه‌سازی با استفاده از یک مدل منطقی در اوایل دهه ۱۹۴۰ توسط وارن مک کالک و والتر پیتز انجام شد که امروزه بلوک اصلی سازنده اکثر شبکه‌های عصبی مصنوعی است. عملکرد این مدل مبتنی‌بر جمع ورودی‌ها و ایجاد خروجی با استفاده از شبکه‌ای از نورون‌ها است. اگر حاصل جمع ورودی‌ها از مقدار آستانه بیشتر باشد، اصطلاحاً نورون برانگیخته می‌شود. نتیجه این مدل اجرای ترکیبی از توابع منطقی است.

۳-۴- ایجاد مدل ترکیبی

پس از ارزیابی عملکرد جداگانه هر یک از مدل‌ها، برای بهبود دقت پیش‌بینی، بهترین مدل‌ها با یکدیگر ترکیب شدند. ترکیب مدل BiLSTM با CNN به‌عنوان بهترین روش انتخاب گردید. در این ترکیب، خروجی مدل BLSTM را که حاصل پردازش اولیه بر روی مجموعه داه‌ها است پس از اعمال مکانیزم توجه بر روی مجموعه داده‌ها با خروجی شبکه عصبی پیچشی (CNN) ترکیب می‌شوند. دلیل بهتر بودن نتیجه مدل ترکیبی BiLSTM و CNN به توانایی‌های منحصربه‌فرد هر یک از این مدل‌ها و نحوه ترکیب آن‌ها برمی‌گردد. در ادامه به دلایل اصلی برتری این مدل ترکیبی اشاره می‌شود.

۳-۴-۱- استفاده از نقاط قوت BiLSTM

حافظه بلند-کوتاه‌مدت دوطرفه (BiLSTM) توانایی پردازش داده‌های متنی را از دو جهت (گذشته به آینده و آینده به گذشته) دارد. این ویژگی به مدل اجازه می‌دهد تا وابستگی‌های طولانی‌مدت و الگوهای پیچیده‌تر در نظرات مسافران را بهتر درک کند. همچنین BiLSTM می‌تواند ارتباطات معنایی بین کلمات را در متن بهتر تشخیص دهد، که این موضوع در تحلیل احساسات و پیش‌بینی رضایت مسافران بسیار مهم است.

۳-۴-۲- استفاده از نقاط قوت CNN

شبکه عصبی پیچشی (CNN) توانایی بالایی در استخراج ویژگی‌های مهم از داده‌ها دارد. این مدل می‌تواند الگوهای محلی و مهم را در داده‌های متنی شناسایی کند و آن‌ها را برای پیش‌بینی دقیق‌تر استفاده کند. همچنین، CNN با فشرده‌سازی داده‌ها و استخراج ویژگی‌های مرتبط، باعث کاهش حجم محاسبات و افزایش سرعت یادگیری مدل می‌شود.

۳-۴-۳- ترکیب[۱۸] BLSTM وCNN

BiLSTM برای پردازش توالی‌های طولانی‌مدت و درک زمینه زبانی مناسب است، در حالی که CNN برای استخراج ویژگی‌های محلی و کاهش پیچیدگی داده‌ها به‌کار می‌رود. ترکیب این دو مدل باعث می‌شود که مدل نهایی هم بتواند وابستگی‌های زمانی را درک کند و هم ویژگی‌های مهم را از داده‌ها استخراج کند. به‌عبارتی، نقاط

قوت یکدیگر را تکمیل می‌کنند. همچنین، ترکیب خروجی‌های BiLSTM و CNN باعث می‌شود که مدل نهایی اطلاعات جامع‌تری از داده‌ها داشته باشد و بتواند پیش‌بینی دقیق‌تری انجام دهد. مدل نهایی شامل یک لایه BLSTM با ۱۲۸ نورون و فعال‌سازی ReLU است. برای جلوگیری از بیش‌برازش از مکانیزم توجه استفاده شد. در بخش CNN، از یک لایه کانولوشنی با ۶۴ فیلتر و kernel size=3 استفاده شد. پس از آن، دو لایه Fully Connected با ۶۴ نورون به‌کار رفته‌اند. نرخ یادگیری در الگوریتم Adam برابر با ۰،۰۰۱ و تعداد epoch برابر ۱۰ در نظر گرفته شده است. مقدار batch size برابر با ۳۲ انتخاب شده و از Dropout استفاده نشده است.

۳-۵- نقش مکانیزم توجه در بهبود عملکرد مدل

مکانیزم توجه در این مدل نقش کلیدی در بهبود عملکرد دارد. مدل‌های BiLSTM و CNN به‌تنهایی قادر به استخراج ویژگی‌های متنی هستند، اما بدون مکانیزم توجه، مدل ممکن است اطلاعات مهم را نادیده بگیرد. مکانیزم توجه با تخصیص وزن‌های بیشتر به بخش‌های مهم متن، باعث می‌شود که مدل بهتر بتواند ارتباطات معنایی بین کلمات را درک کند. این امر به‌ویژه در داده‌های متنی پیچیده که شامل جزئیات زیاد است، عملکرد مدل را بهبود می‌بخشد. نتایج نشان می‌دهد که مدل دارای مکانیزم توجه دقت بالاتری در مقایسه با مدل‌های BiLSTM و CNN بدون این مکانیزم دارد. با توجه به این ساختار، مدل پیشنهادی توانایی بالایی در پیش‌بینی میزان رضایتمندی مسافران دارد و می‌تواند به شرکت‌های هواپیمایی در بهینه‌سازی خدمات کمک کند.

۴- نتایج آزمایش‌ها

برای ارزیابی مدل پیشنهادی، مجموعه داده شامل ۱۲۹۸۸۰ نمونه به دو بخش داده‌های آموزشی (۷۰٪) و داده‌های آزمایشی (۳۰٪) تقسیم شد. در این بخش، به‌منظور بررسی اولیه رفتار مدل در ساختارهای مختلف، نتایج حاصل از چند پیکربندی آورده شده‌اند. لازم به ذکر است که تنظیم نهایی پارامترهای مدل (از جمله تعداد نورون‌ها، ساختار لایه‌ها و نرخ یادگیری) صرفاً بر اساس داده‌های اعتبارسنجی انجام شده و فقط پیکربندی بهینه‌شده برای ارزیابی نهایی مدل به کار گرفته شده است. همچنین، نتایج حاصل از مدل‌های مختلف مورد بررسی قرار گرفته و تأثیر مکانیزم توجه در بهبود عملکرد مدل تحلیل شده است. عملکرد مدل‌های مختلف با استفاده از معیارهای دقت[۱۹]، یادآوری[۲۰]، دقت پیش‌بینی[۲۱] و F1-Score اندازه‌گیری شد.

$$Precision = \frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FP}} \quad (۱)$$

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

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall} \quad (۳)$$

معیار دقت به عبارتی نسبت کل پیش بینی‌های صحیح شامل مثبت و منفی به کل داده‌هاست و نشان دهنده توانایی کلی مدل در پیش بینی صحیح است. معیار دقت پیش بینی نسبت پیش بینی‌های صحیح مثبت به کل پیش بینی‌های مثبت است. هر چقدر میزان پیش بینی‌های مثبت که بصورت غلط می‌باشند کمتر باشد در نتیجه مقدار معیار دقت پیش بینی بیشتر شده و به عدد ۱ نزدیکتر می‌گردد. محیط پیاده سازی مورد استفاده Google Colab می‌باشد. پیاده‌سازی این پژوهش در گیت‌هاب[۲۲] به اشتراک گذاشته شده است.

۴-۱- مقایسه عملکرد مدل‌های مختلف

در این پژوهش، چهار مدل مختلف مورد آزمایش قرار گرفتند: BiLSTM، CNN، ترکیب BiLSTM و CNN، ترکیب BiLSTM، CNN و مکانیزم توجه (مدل پیشنهادی).

مدل‌های مورد استفاده در این پژوهش هر کدام دارای نقاط قوت و ضعفی می‌باشند. به‌منظور به‌دست آوردن بهترین میزان دقت، بایستی از نقاط قوت نهایت استفاده را برده و تا حد امکان نقاط ضعف بی‌اثر گردند. در این پژوهش از مدل BLSTM استفاده شده است که به پردازش اطلاعات از دو جهت (جلو و عقب) می‌پردازند. این ویژگی به آن‌ها اجازه می‌دهد تا از اطلاعات بیشتری در زمان پردازش داده‌های توالی‌دار بهره‌برداری کنند. با استفاده از اطلاعات گذشته و آینده، اطلاعات پیچیده تری را مدل سازی می‌کنند. یکی از معایب این مدل به مانند مدل LSTM، دشواری تنظیم هایپر پارامترها و همچنین زمان زیاد پردازش است. یکی دیگر از مدل‌های شبکه عمیق که در این پژوهش مورد استفاده قرار گرفت مدل شبکه عصبی پیچشی (CNN) است. یکی از مزایای مهم این مدل، کاهش زمان پیش‌پردازش داده‌ها است. به عبارتی مدل CNN بصورت خودکار ویژگی‌های مهم را از داده‌ها استخراج می‌کند. از دیگر مزایای این مدل می‌توان به مقیاس‌پذیری آن اشاره کرد که به‌راحتی برای حل مسائل مختلف قابل تنظیم است. با توجه به مزایای مطرح شده بهترین نتیجه مربوط به مدل CNN در مقایسه با مدل دیگر است. در ادامه، نتایج بدست آمده در رابطه با هر مدل بصورت مجزا ارائه شده است.

۴-۲- نتایج مدل BLSTM

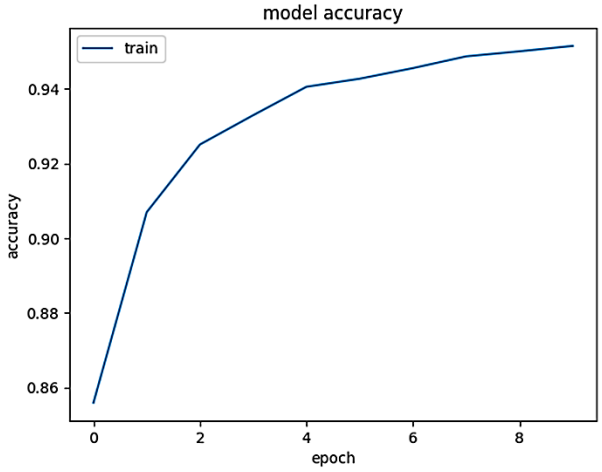
پس از بررسی اولیه ساختارهای مختلف، پیکربندی نهایی مدل BLSTM شامل ۲ لایه پنهان با ۶۴ نورون، ورودی ۱۲۸ نورونی برای BiLSTM انتخاب شد. نتایج نهایی بر روی داده‌های آزمایشی در جدول ۱ گزارش شده‌اند. همچنین، در شکل ۲ میزان دقت این مدل با تعداد دفعات یادگیری epochs=10 نشان داده شده است.

جدول ۱- نتایج بدست آمده از الگوریتم BLSTM

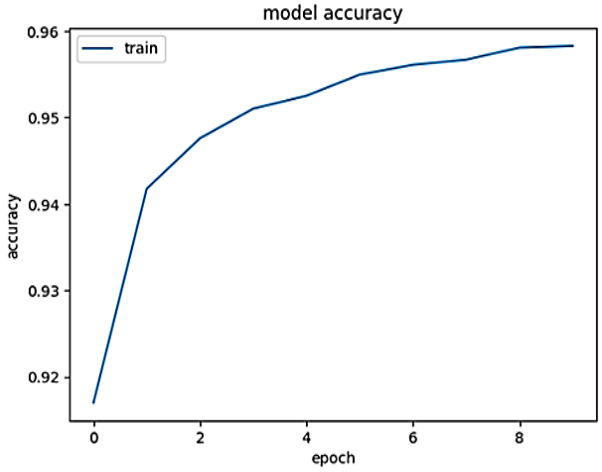
مدل	Acc.	Recal1	Precision	AUC	F1
BLSTM (64) without dense	۰/۹۴۷	۰/۹۵۸	۰/۹۴۵	۰/۹۴۴	۰/۹۵۲
BLSTM (64) with dense (64)	۰/۹۵۱	۰/۹۴۱	۰/۹۶۹	۰/۹۵۲	۰/۹۵۵
BLSTM (64) with dense (2*32)	۰/۹۴۷	۰/۹۴۷	۰/۹۵۶	۰/۹۴۷	۰/۹۵۱
BLSTM (64) with dense (128)	۰/۹۴۲	۰/۹۶۱	۰/۹۳۶	۰/۹۴۰	۰/۹۴۸
BLSTM (64) with dense (4*32)	۰/۹۴۹	۰/۹۴۵	۰/۹۶۰	۰/۹۴۹	۰/۹۵۱
BLSTM (128) without dense	۰/۹۵۰	۰/۹۴۹	۰/۹۶۰	۰/۹۵۱	۰/۹۵۴
BLSTM (128) with dense (64)	۰/۹۵۱	۰/۹۴۸	۰/۹۶۱	۰/۹۵۱	۰/۹۵۵
BLSTM (128) with dense (2*32)	۰/۹۵۲	۰/۹۵۱	۰/۹۶۰	۰/۹۵۲	۰/۹۵۵
BLSTM (128) with dense (128)	۰/۹۵۱	۰/۹۳۹	۰/۹۷۱	۰/۹۵۲	۰/۹۵۴
BLSTM (128) with dense (4*32)	۰/۹۵۴	۰/۹۴۴	۰/۹۷۱	۰/۹۵۵	۰/۹۵۷

۴-۳- نتایج مدل CNN

در این قسمت مجموعه داده به یک شبکه عصبی پیچشی اعمال و نتایج بدست آمده در جدول ۲ نمایش داده شده است. با توجه به نتایج بدست آمده مشاهده می‌شود که در بهترین حالت که از چهار لایه ۳۲ نورونی که جمعا ۱۲۸ نورون می‌باشد معیار F1 برابر با ۹۶/۰۶ درصد است. شکل ۳ روند افزایش دقت در این مدل را نسبت به مدل قبلی نشان می‌دهد.



شکل ۲- منحنی میزان دقت در مدل BLSTM



شکل ۳- منحنی میزان دقت در مدلCNN

جدول ۲-نتایج بدست آمده از الگوریتم CNN

Model	Acc.	Recall	Precision	AUC	F1
CNN	۰/۹۲۲	۰/۹۳۵	۰/۹۲۳	۰/۹۲۱	۰/۹۲۹
CNN (64)	۰/۹۵۵	۰/۹۴۹	۰/۹۶۹	۰/۹۵۶	۰/۹۵۷
CNN (2*32)	۰/۹۵۵	۰/۹۵۶	۰/۹۶۲	۰/۹۵۵	۰/۹۵۹
CNN (128)	۰/۹۵۷	۰/۹۵۶	۰/۹۶۴	۰/۹۵۶	۰/۹۶۰
CNN (4*32)	۰/۹۵۷	۰/۹۵۰	۰/۹۷۲	۰/۹۵۸	۰/۹۶۱

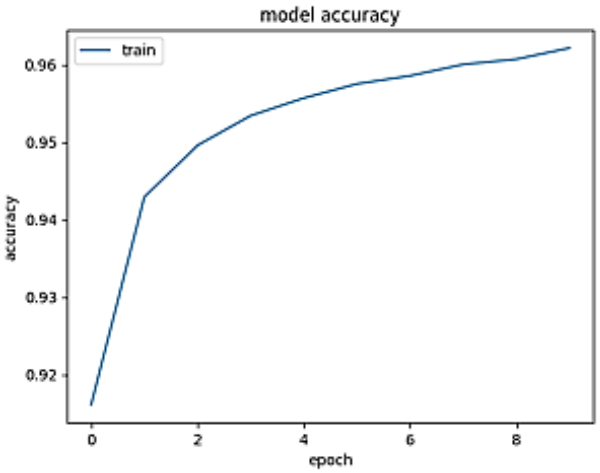
۵- نتایج مدل پیشنهادی

در این مرحله، خروجی دو الگوریتم BLSTM و CNN با یکدیگر ترکیب شده است.

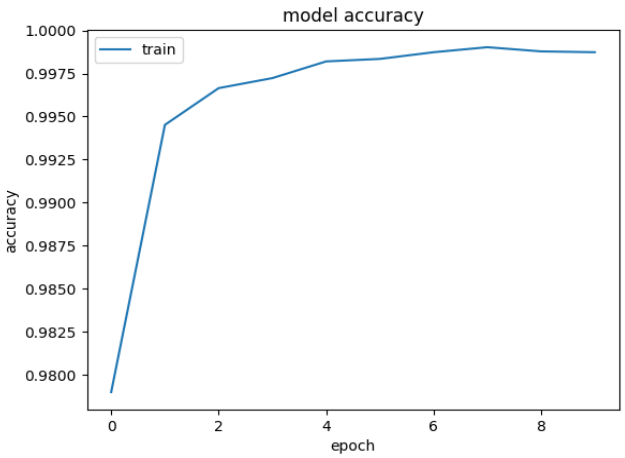
در ادامه، مکانیزم توجه به‌مدل اضافه می‌شود. مکانیزم توجه به مدل کمک می‌کند تا بر روی بخش‌های مهم متن تمرکز بیشتری داشته باشد و ویژگی‌های کلیدی را بهتر شناسایی کند. همانطور که در جدول ۳ نمایش داده شده است، با مقایسه مدل BiLSTM + CNN با مدل پیشنهادی (BiLSTM with Att. + CNN)، مشاهده شد که مکانیزم توجه باعث کاهش نرخ خطای پیش‌بینی و افزایش دقت در شناسایی نظرات مسافران شده است. منحنی میزان دقت در دو حالت متفاوت نمایش داده شده است که در شکل ۴ از مکانیزم توجه استفاده نشده است و در شکل ۵ از مکانیزم توجه استفاده شده است.

جدول ۳- نتایج بدست آمده از ترکیب الگوریتم BLSTM و CNN

مدل	Acc.	Recal1	Precision	AUC	F1
Concatenate BLSTM (128) &CNN (4*32) Without attention	۰/۹۵۲	۰/۹۲۳	۰/۹۸۷	۰/۹۵۵	۰/۹۵۵
BLSTM (128) &CNN (2*64) Without attention	۰/۹۶۰	۰/۹۵۲	۰/۹۷۳	۰/۹۶۱	۰/۹۶۳
BLSTM (128) (4*32) & CNN (2*64) Without attention	۰/۹۵۶	۰/۹۴۸	۰/۹۷۹	۰/۹۵۶	۰/۹۵۹
BLSTM (128) (2*32) &LSTM (128) Without attention	۰/۹۵۲	۰/۹۵۱	۰/۹۶۱	۰/۹۵۲	۰/۹۵۵
BLSTM (128) &CNN (2*64) With attention	۰/۹۹۸	۰/۹۹۹	۰/۹۹۷	۰/۹۹۸	۰/۹۹۸



شکل ۴- منحنی میزان دقت در مدل BLSTM+CNN



شکل ۵- منحنی میزان دقت در مدل BLSTM+CNN با مکانیزم توجه

۵-۱- مقایسه با کارهای پیشین

نتایج گزارش‌شده، مربوط به اجرای نهایی مدل با پارامترهای تنظیم‌شده بر اساس مجموعه داده اعتبارسنجی می‌باشد. این پیکربندی شامل نرخ یادگیری ۰/۰۰۱، تعداد epoch برابر با ۱۰، ۱۲۸ نورون در BLSTM و ساختار CNN با ۶۴ فیلتر و دو لایه Fully Connected با ۶۴ نورون بوده است. این پیکربندی به‌عنوان ساختار نهایی مدل جهت ارزیابی بر روی مجموعه داده تست مورد استفاده قرار گرفته است. برای ارزیابی اثربخشی مدل پیشنهادی، عملکرد آن با نتایج پژوهش‌های مشابه در حوزه پیش‌بینی رضایتمندی مسافران مقایسه شد. در برخی مطالعات، از روش‌های یادگیری ماشین سنتی مانند SVM، جنگل تصادفی و XGBoost استفاده شده است که دقتی در حدود۸۲ ٪ تا ۹۵٪ داشته‌اند. اگرچه این مدل‌ها در تحلیل داده‌های ساختاریافته عملکرد مناسبی دارند، اما در پردازش داده‌های متنی و استخراج الگوهای پیچیده با محدودیت‌هایی مواجه هستند.

نتایج در جدول ۴ برای مدل‌های به‌کار رفته به همراه بهترین مقدار پارامتر F1 به منظور مقایسه آنها با یکدیگردرج شده است. نتایج نشان می‌دهند که مدل پیشنهادی نسبت به روش‌های پیشین مانند BLSTM و CNN مجزا عملکرد بهتری داشته است. اضافه شدن مکانیزم توجه به BiLSTM موجب بهبود دقت مدل شده است. همچنین، ترکیب BiLSTM + Att با CNN باعث شده که مدل بتواند ویژگی‌های محلی و وابستگی‌های طولانی‌مدت را به‌صورت هم‌زمان پردازش کند، که این امر تأثیر مثبتی بر عملکرد مدل داشته

است.

همچنین، مقایسه با پژوهش‌های پیشین نشان می‌دهد که مدل پیشنهادی بهبود قابل‌توجهی در دقت و معیارهای ارزیابی دارد. استفاده از مکانیزم توجه به‌مدل کمک کرده تا اطلاعات مهم‌تر در متن را بهتر تشخیص دهد و تأثیر نویز را کاهش دهد.

به‌طور کلی، نتایج آزمایش‌ها تأیید می‌کنند که ترکیب BiLSTM، CNN و مکانیزم توجه باعث بهبود چشمگیر عملکرد مدل پیشنهادی شده است و می‌تواند در کاربردهای پردازش زبان طبیعی و تحلیل متون به‌عنوان یک روش کارآمد مورد استفاده قرار گیرد.

جدول ۴-بهترین مقادیر F1 برای مدلهای مختلف (* مدل پیشنهادی)

مدل	F1
Support Vector Machine [10]	۰/۸۷۰
Support Vector Machine [12]	۰/۹۵۲
XGBoost [13]	۰/۹۵۷
Random Forest [7]	۰/۸۸۸
Naïve Bayes [8]	۰/۸۲۳
Random Forest [9]	۰/۹۴۶
BLSTM (128) with dense (4*32)	۰/۹۵۷
CNN (4*32)	۰/۹۶۱
Concatenate BLSTM (128) &CNN (2*64) without Attention	۰/۹۶۳
*Concatenate BLSTM (128) &CNN (2*64) with Attention	۰/۹۹۸

همانطوریکه از نتایج بدست آمده مشخص است بهترین ترکیب مربوط به BLSTM(128) و CNN(2*64) با مکانیزم توجه می‌باشد. یکی از دلایل کسب این نتیجه در مقایسه با سایر ترکیب‌ها این است که تعداد لایه‌های پنهان را از چهار لایه به دو لایه کاهش دادیم که دلیل این مورد در استفاده کمتر از پارامترها در مدل و جلوگیری از سرریز شدن مدل می‌باشد. وقتی تعداد لایه‌های مدل را کمتر می کنیم به عبارتی تعداد تابع فعال سازی (Relu) که تابعی غیر خطی هم میباشد را هم کمتر کردیم. شایان ذکر است در مقاله منتشر شده در سال ۲۰۲۱ برای مدل جنگل تصادفی استفاده شده میزان Max Depth=17 قرارداده شده که عمق بسیار زیادی در مدل بوجود می آید. در مدل جنگل تصادفی استفاده شده در مقالات مورد اشاره تعداد پارامترهای مورد استفاده بیشتر از مدل ترکیبی این پژوهش می‌باشد که این مطلب به تنهایی باعث عملکرد بهتر مدل ترکیبی نسبت به مدل‌های پیشین می‌گردد. نکته مهم دیگری که بایستی در نظر گرفت مربوط به سرعت پردازش مدل است که نباید با تاخیر باشد و زمان زیادی مصرف کند. در این پژوهش تعداد Epochs=10 انتخاب شده بود که در مقایسه با پارامترهای تنظیم شده در مقالات مرتبط بسیار مناسب‌تر هستند. اگرچه ترکیب BiLSTM و CNN نتایج خوبی در تحلیل داده‌های متنی ارائه می‌دهد، اما بدون استفاده از مکانیزم توجه، مدل نمی‌تواند بر اطلاعات مهم‌تر تمرکز کند. افزودن مکانیزم توجه به مدل پیشنهادی این محدودیت را برطرف کرده و دقت پیش‌بینی را افزایش داده است.

۵-۲- تحلیل نتایج ماتریس درهم‌ریختگی[۲۳]

ماتریس درهم‌ریختگی ابزاری است که برای ارزیابی عملکرد یک مدل طبقه‌بندی استفاده می‌شود .این ماتریس که با نام ماتریس خطا نیز شناخته می‌شود، معمولاً به صورت یک جدول مربعی نمایش داده می‌شود و امکان نمایش دیداری عملکرد یک الگوریتم را فراهم می‌کند. در این جدول، نتایج پیش‌بینی مدل در مقابل نتایج واقعی قرار می‌گیرند. ماتریس درهم‌ریختگی بصورت یک ماتریس ۲*۲ می‌باشد و اجزای آن به صورت زیر تعریف می‌شوند:

TP[۲۴]: یعنی بصورت صحیح پیش‌بینی درست (رضایتمندی) انجام شده است.

TN[۲۵]: یعنی بصورت صحیح پیش‌بینی نادرست (عدم رضایتمندی) انجام شده است.

FP[۲۶]: یعنی بصورت اشتباه پیش‌بینی درست (رضایتمندی) انجام شده است.

FN[۲۷]: یعنی بصورت اشتباه پیش‌بینی نادرست (عدم رضایتمندی) انجام شده است.

از این ماتریس می‌توان برای محاسبه شاخص‌های مهم ارزیابی عملکرد مانند دقت، یادآوری، مقدار F1 و دقت پیش‌بینی استفاده کرد. تحلیل دقیق این مقادیر می‌تواند به درک بهتر عملکرد مدل و شناسایی نقاط ضعف آن کمک کند. مقادیر بدست آمده برای معیارهای فوق در جدول ۵ نمایش داده شده است.

جدول ۵- نتایج ماتریس درهم‌ریختگی برای مدل پیشنهادی

واقعی / پیش‌بینی شده	نادرست(0)	درست(1)
درست(0)	**FN** (1)	**TP** (4385)
نادرست(0)	**TN** (4436)	**FP** (11)

با توجه به نتایج بدست آمده مشاهده می‌شود که معیار F1 که از رابطه (۳) درج شده در بخش ۴ محاسبه می‌گردد در بهترین حالت عملکرد مدل برابر ۰/۹۹۸۶ است. نتیجه مذکور بیانگر دقت بالای

مدل در پیش‌بینی میزان رضایتمندی مسافران خطوط هوایی از شرکت‌های سرویس‌دهنده است.

۶- نتیجه‌گیری و پیشنهادها

همانطوریکه قبلا اشاره شد یکی از مهمترین صنایع جهان، صنعت هوایی است. با عنایت به رشد روز افزون تکنولوژی نیاز به استفاده از این ابزار در راستای پیشرفت و کسب در آمد برای هر نوع صنعتی امری حیاتی است. مشتریان بخش عمده و درصد قابل توجهی از هر نوع تجارت به حساب می‌آیند. پیش بینی درست از نیازهای آن‌ها می‌تواند به پایدار بودن تجارت مربوطه و همچنین کسب در آمد بیشتر مجموعه فوق کمک نماید.

در این پژوهش، یک مدل ترکیبی مبتنی بر BiLSTM و CNN همراه با مکانیزم توجه برای پیش‌بینی رضایتمندی مسافران ارائه شد. هدف اصلی این تحقیق، ارائه مدلی کارآمد برای تحلیل نظرات مسافران و پیش‌بینی میزان رضایت آن‌ها از خدمات خطوط هوایی بود. نتایج نشان داد که ترکیب BiLSTM و CNN عملکرد بهتری نسبت به مدل‌های منفرد داشته و افزودن مکانیزم توجه باعث بهبود قابل‌توجهی در دقت، یادآوری و معیار F1 شده است. مدل پیشنهادی با دقت ۹۹/۸٪ می‌تواند به‌عنوان ابزاری موثر در بهینه‌سازی تجربه مشتری و افزایش وفاداری مسافران به کار گرفته شود. با این حال، این پژوهش می‌تواند در جهت‌های مختلفی گسترش یابد. از جمله پیشنهادها برای تحقیقات آینده عبارتند از: (۱) استفاده از مدل‌های مبتنی‌بر Transformer مانند BERT یا GPT برای بهبود درک عمیق‌تر از نظرات متنی مسافران. (۲) گسترش مجموعه داده‌ها به داده‌های چندزبانه و متنوع‌تر جهت افزایش تعمیم‌پذیری مدل. (۳) استفاده از تکنیک‌های افزایش داده[۲۸] برای بهبود عملکرد در سناریوهایی با داده‌های نامتوازن. (۴) بررسی تأثیر سایر مکانیزم‌های توجه مانند توجه چندسری[۲۹] برای افزایش دقت مدل.

به‌طور کلی، مدل پیشنهادی نشان داد که یادگیری عمیق، همراه با مکانیزم توجه، می‌تواند ابزاری مؤثر برای پیش‌بینی رضایتمندی مسافران باشد و از این طریق به بهبود کیفیت خدمات در صنعت هوایی کمک کند.

مراجع

[1] Choi, J., Seol, H., Lee, S., Cho, H., & Park, Y. (2008). Customer satisfaction factors of mobile commerce in Korea. Internet research, 18(3), 313-335.

[2] Behn, B. K., & Riley Jr, R. A. (1999). Using nonfinancial information to predict financial performance: The case of the US airline industry. Journal of Accounting, Auditing & Finance, 14(1), 29-56.

[3] Hariguna, T., Baihaqi, W. M., & Nurwanti, A. (2019). Sentiment analysis of product reviews as a customer recommendation using the naive Bayes classifier algorithm. International Journal of Informatics and Information Systems, 2(2), 48-55.

[4] Chen, C. F. (2008). Investigating structural relationships between service quality, perceived value, satisfaction, and behavioral intentions for air passengers: Evidence from Taiwan. Transportation Research Part A: Policy and Practice, 42(4), 709-717.

[5] Weng, J., Yu, J., Di, X., Lin, P., Wang, J. J., & Mao, L. Z. (2023). How does the state of bus operations influence passengers' service satisfaction? A method considering the differences in passenger preferences. Transportation Research Part A: Policy and Practice, 174, 103734.

[6] Tiernan, S., Rhoades, D. L., & Waguespack, B. (2008). Airline service quality: Exploratory analysis of consumer perceptions and operational performance in the USA and EU. Managing Service Quality: An International Journal, 18(3), 212-224. doi: 10.1108/09604520810871847.

[7] Hong, A. C. Y., KHAW, K. W., Chew, X., & Yeong, W. C. (2023). Prediction of US airline passenger satisfaction using machine learning algorithms. Data Analytics and Applied Mathematics (DAAM), 7-22.

[8] Nurdina, A., & Puspita, A. B. I. (2023). Naive Bayes and KNN for Airline Passenger Satisfaction Classification: Comparative Analysis. Journal of Information System Exploration and Research, 1(2).

[9] Hayadi, B. H., Kim, J. M., Hulliyah, K., & Sukmana, H. T. (2021). Predicting Airline Passenger Satisfaction with Classification Algorithms. International Journal of Informatics and Information Systems, 4(1), 82-94.

[10] Pereira, F., Costa, J. M., Ramos, R., & Raimundo, A. (2023). The impact of the COVID-19 pandemic on airlines' passenger satisfaction. Journal of Air Transport Management, 112, 102441.

[11] Dike, S. E., Davis, Z., Abrahams, A., Anjomshoae, A., & Ractham, P. (2024). Evaluation of passengers' expectations and satisfaction in the airline industry: an empirical performance analysis of online reviews. Benchmarking: An International Journal, 31(2), 611-639.

[12] Mirthipati, T. (2024). Enhancing Airline Customer Satisfaction: A Machine Learning and Causal Analysis Approach. arXiv preprint arXiv:2405.09076.

[13] Ibrahim, A. O., Yi, C. C., Elsafi, A., & Ghaleb, F. A. (2023, December). Revolutionizing Airline Customer Satisfaction Analysis with Machine Learning Techniques. In International Conference of Reliable Information and Communication Technology (pp. 141-152). Cham: Springer Nature Switzerland.

[14] Shahid, R., Mozumder, M. A. S., Sweet, M. M. R., Hasan, M., Alam, M., Rahman, M. A, & Islam, M. R. (2024). Predicting Customer Loyalty in the Airline Industry: A Machine Learning Approach Integrating Sentiment Analysis and User Experience. International Journal on Computational Engineering, 1(2), 50-54.

[15] Salehinejad, H., Sankar, S., Barfett, J., Colak, E., & Valaee, S. (2017). Recent advances in recurrent neural networks. arXiv preprint arXiv:1801.01078.

[16] Liyanage, S., Abduljabbar, R., Dia, H., & Tsai, P. W. (2022). AI-based neural network models for bus passenger demand forecasting using smart card data. Journal of Urban Management, 11(3), 365-380.

[17] Parnian P. (2022). Customer Reviews Classification with Text Mining and Deep Learning Approach (Case Study: Digikala Customers Reviews), 14(4), 675-694 doi: https://doi.org/10.22059/JIBM.2022.334338.4255

[18] Park, S.-H., Kim, M.-Y., Kim, Y.-J., & Park, Y.-H. (2022). A Deep Learning Approach to Analyze Airline Customer Propensities: The Case of South Korea. *Applied Sciences*, *12*(4), 1916. https://doi.org/10.3390/app12041916

[19] Ouf, S. (2023). An optimized deep learning approach for improving airline services. *Computers, Materials & Continua*, *75(1)*, 1213–1233. https://doi.org/10.32604/cmc.2023.034399

پاورقی‌ها:

1 Convolutional Neural Network
2 Bidirectional Long Short-Term Memory
3 Attention Mechanism
4 Random Forest
5 Support Vector Machine
6 Naïve Bayes
7 Logistic Regression
8 https://www.airlinequality.com/
9 Decision Tree
10 Logistic Regresion
11 https://www.kaggle.com/datasets/johnddddd/customer-satisfaction
12 Word Embedding
13 Concatenate
14 Dense
15 Not a Number
16 Multilayer perceptron
17 Time delay Neural Network
18 Concatenate
19 Accuracy
20 Recall
21 Precision
22 https://github.com/zjahanbakhsh/Predicting-Airline-Passenger-Satisfaction-by-BLSTM-CNN/blob/main/BLSTM-CNN-Attention.ipynb
23 Confusion Matrix
24 True Positive
25 True Negative
26 False Positive
27 False Negative
28 Data Augmentation
29 Multi-Head Attention