

طراحی مدلی هوشمند جهت پیش‌بینی ریسک ایمنی پرواز - فاز فرود با استفاده از الگوریتم BI.M-LSTM

مقاله علمی - پژوهشی

منصور یحیوی، دانشجوی دکتری، دانشکده مدیریت، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران
عباس طلوعی اشلفی*، استاد، دانشکده مدیریت و اقتصاد، دانشگاه علوم و تحقیقات دانشگاه آزاد اسلامی، تهران، ایران
محمد علی افشار کاظمی، استاد، دانشکده مدیریت و اقتصاد، دانشگاه علوم و تحقیقات دانشگاه آزاد اسلامی، تهران، ایران
رضا رادفر، استاد، گروه مدیریت تکنولوژی، دانشگاه آزاد اسلامی، واحد علوم تحقیقات تهران، تهران، ایران

*پست الکترونیکی نویسنده مسئول: toloie@gmail.com

دریافت: ۱۴۰۴/۰۱/۳۰ - پذیرش: ۱۴۰۴/۰۵/۰۱

صفحه ۴۹۰ - ۴۷۷

چکیده

مقاله حاضر، مدلی نوآورانه (BI.M-LSTM) ترکیبی از الگوریتم (BI) و شبکه عصبی بازگشتی (LSTM) جهت پیش‌بینی ریسک ایمنی پرواز فاز فرود لندنینگ برای نخستین بار ارائه می‌دهد. فاز لندنینگ به عنوان یکی از حساس‌ترین مراحل پرواز، نیازمند دقت و کنترل بالا از سوی خدمه پروازی است، چرا که درصد قابل توجهی از حوادث هوایی در این مرحله رخ می‌دهد. روش پژوهش، آموزش شبکه عصبی بازگشتی نظارت شده برای برآورد پارامترهای هدف است. داده‌های مورد استفاده شامل بیش از ۲۸ هزار رکورد سری‌زمانی پروازی است که از دیتاست استاندارد مربوط به سال ۲۰۱۹ تا ۲۰۲۰ پس از پاکسازی، نرمال‌سازی پارامترهای ریسک ایمنی فرود، همچون شرایط آب و هوایی فرودگاه، پیکربندی هواپیما، ترافیک هوایی سرعت و ارتفاع انتخاب شد. به علت وابستگی داده‌های پرواز به ورودی‌های ما قبل خود و نیاز به نوعی حافظه، آموزش داده‌ها توسط الگوریتم (LSTM) انجام گرفت. پس از یادگیری، میانگین خطای مجذور انحرافات حدود ۶/۱۲۵ درصد بدست آمد. نتیجه نشان داد، درصد خطا قابل اغماض و مدل پیشنهادی نسبت به مدل‌های مشابه از اعتبار بسیار خوبی برخوردار است. نتایج نشان می‌دهد که مدل ترکیبی BI.M-LSTM توانسته است با دقت بالا، عوامل پرخطر را شناسایی و احتمال وقوع رویدادهای ناخواسته را پیش‌بینی کند. این یافته‌ها می‌تواند به بهبود سامانه‌های پشتیبان تصمیم‌گیری خلبان و ارتقاء پروتکل‌های ایمنی در فاز لندنینگ کمک نماید.

واژه‌های کلیدی: ریسک ایمنی پرواز، حمل نقل هوایی، لندنینگ، مدل، یادگیری عمیق، BI.M-LSTM

۱- مقدمه

بر بهبود ایمنی در این فاز، نقش کلیدی در کاهش ریسک‌های پروازی ایفا می‌کند. به علت اینکه در این مرحله، هواپیما در ارتفاع پایین، سرعت کم و تحت تأثیر عوامل محیطی مانند بادهای جانبی، دید محدود، و بارش قرار دارد، و همچنین هر خطای انسانی یا فنی می‌تواند فرصت کمی برای جبران داشته باشد. (Yahyavi, et al, 2024) تجزیه و تحلیل داده حوادث گذشته برای جلوگیری از وقوع حوادث مشابه، به عنوان رویکردی موفق به اثبات رسیده است. (Li, et al,

ارزیابی ایمنی در صنعت هوانوردی یک مساله اساسی و مهم است. توجه به ایمنی پرواز یک رویکرد کاهش ریسک جهت نجات جان انسان‌ها، حفظ منافع و جلوگیری از حوادث ناگوار است. (Rey et al, 2021). در میان مراحل مختلف پرواز، فاز لندنینگ به‌عنوان پیچیده‌ترین و خطرناک‌ترین مراحل شناخته می‌شود که حدود ۶۱ درصد از حوادث مرگبار در این مرحله رخ می‌دهد، اگرچه سهم زمانی آن کمتر از ۲ درصد از کل زمان پرواز است. (ICAO, 2022) بنابراین، تمرکز

همکاران (۲۰۱۵) نیز یک چارچوب کنترلی بهینه برای تجزیه و تحلیل قوانین کنترل پرواز پیشنهاد کرد. هوش یای لی و همکاران (۲۰۲۳) با هدف شناخت ضعف انعطاف‌پذیری ارتباط مدل ذهنی خلبان در طول لندینگ هواپیما نشان داد کنترل دیر هنگام کنترل ترافیک هوایی در یک وضعیت لندینگ نامناسب عامل مهمی جهت تشخیص خطای عملکرد انسانی ناهنجاری محیط پرواز است. (Yay, et al, 2023).

نتایج مطالعه الکساندرز و همکاران (۲۰۲۰) نشان داد، ترکیب چندین الگوریتم‌های پیشرفته جهت ارزیابی ایمنی هوانوردی منجر به تسهیل فرآیند استخراج داده‌های حادثه می‌شود. معماری مفهومی تضمین کاهش ریسک ایمنی و تقویت ایمنی یکپارچه هواپیما (AIRSAFE) برای جلوگیری از دست رفتن کنترل پرواز، ارزیابی ایمنی، کنترل انعطاف‌پذیر در موقعیت‌هایی ریسک کمک می‌کند (, Eleksanderz, et al, 2020)

هانگ و همکاران (۲۰۲۲) با ترکیب تجزیه و تحلیل داده‌های سری زمانی و شبکه LSTM جهت کاهش ریسک پرواز الگوی نوآورانه (PS-LE-LSTM) مطرح کردند.

در مراحل پرواز فاز فرود هنگامی که هواپیما وارد یک STAR می‌شود وضعیت سیستم هواپیما مطابق با شناخت نهایی توسط خلبان و خدمه به روز رسانی می‌شود. با نزدیک شدن به هواپیما به باند فرود، کم کم سرعت و ارتفاع کاهش می‌یابد. در پایان لندینگ (STAR 5)، اگر هواپیما نتواند معیارهای لندینگ پایدار را برآورده نماید و شرایط لندینگ نامناسب باشد، خلبان و خدمه پرواز تلاش می‌کند تا ناپایداری لندینگ را کاهش دهد. خلبان برای تسریع لندینگ فلیپ تنظیم می‌کند. با این حال، اگر سرعت هوا یا ارتفاع بیش از حد از STAR ها کنترل نشوند، خلبان ممکن است نتواند به سرعت هواپیما را تثبیت کند. انحراف از STARS، ممکن است به دلایل مختلف از مقررات STARS پیروی نکند. (Hush-Li, 2023) به طوری که تصمیم برای لندینگ یا رد آن در این مرحله است محاسبه یا پیش‌بینی مسافت‌های عملیاتی هواپیما تجزیه و تحلیل عملکرد یکی دیگر از ارزیابی ریسک است آلتیمر رادیویی، در صورت نصب، با نشان دادن ارتفاع دقیق بالای باند به خلبان در تعیین نقطه مناسب برای شروع فلیپ کمک کند. اگر فلیپ به درستی انجام نشود، ممکن

(2023) برای برنامه‌های پیشگیری موثر، شناسایی عوامل اصلی و وابسته در بروز سوانح ضروری است. داده‌های خام پرواز مانند ضبط کننده دسترسی سریع، ضبط کننده داده‌های پرواز و داده‌های ایمنی پردازش شده است. (Bitins, et al, 2022) انبوه داده‌های جعبه سیاه، نیازمند عملیات پردازش سریع و به موقع است که سیستم‌های حاضر مدیریت ایمنی پرواز (FSM) که از روش‌های فیزیکی، فازی، آماری برای تجزیه و تحلیل داده پرواز استفاده می‌شود. به دلیل پیچیدگی محاسباتی توأم با خطا و نیز زمان پردازش، نمی‌تواند ریسک ایمنی پرواز را با دقت و به موقع ارزیابی نماید. (Zhi Lu et al, 2018) بررسی ایمنی پرواز با افزایش گزارش حوادث و رشد صنایع حمل و نقل هوایی تجاری پرهزینه است. (Gallo, et al, 2022)

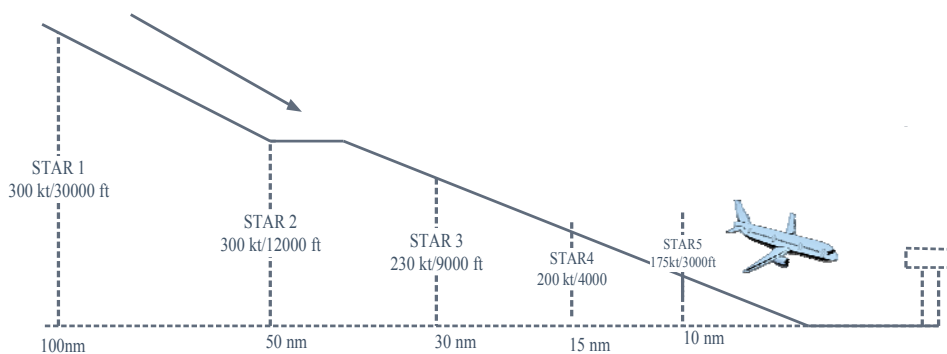
مطالعات زیادی جهت بهبود ایمنی هوانوردی و توسعه معیارهای دقیق به منظور کاهش سوانح هوایی به وسیله یادگیری ماشین انجام شده است. (Aysha, et al, 2024) الگوریتم یادگیری ماشین، جنگل تصادفی (RF)، ماشین‌های بردار پشتیبان (SVM) و رگرسیون لجستیک برای کشف ارتباط بین شاخص ریسک بیش از حد و داده‌های پارامتر پرواز به کار می‌رود. از مدل SVM برای شناسایی ریسک موجود در سیستم الکترونیکی و هیدرولیکی بر اساس وضعیت هر جزء سیستم هواپیما استفاده می‌شود. با توسعه یادگیری عمیق، مدل‌هایی مانند LSTM، AE نتایج قابل قبولی در ستجش ریسک به دست می‌آید. (Zhe et al, 2020) هانگ سان و همکاران (۲۰۲۲) ماشین‌بردار پشتیبان (SVM) ژو و همکاران (۲۰۱۱) راه جدیدی برای پیش‌بینی مشکلات پروازی در جهت ریسک ایمنی هموار نمود. (Zhe, et al, 2022) آیشا و همکاران (۲۰۲۴) جهت پیش‌بینی ریسک فرایند پروچ و لندینگ از روش یادگیری عمیق مرتبط با یک فاز پروازی استفاده کرد. تی جاس جی و همکاران (۲۰۲۰) پیش‌بینی معیارهای ایمنی در حمل و نقل هوایی با استفاده از یادگیری ماشینی نظارت شده با هدف یک مدل پیش‌بینی جهانی برای معیارهای عملکرد لندینگ توسعه دادند. (, Puranik, et al, 2023). نتایج مطالعه جری و همکاران (۲۰۲۰) نشان داد، برآورد پارامترهای، مانند جریان سوخت، تنظیم فلیپ‌ها و چرخ خطای ریسک ایمنی را کاهش می‌دهد. گویندارجان و

برای تحلیل داده‌های حجم پروازی است، و شبکه بازگشتی LSTM، تلاش می‌کند تا چارچوبی کارآمد برای تحلیل داده‌های ایمنی فاز لندینگ و پیش‌بینی ریسک ارائه نماید. این مقاله در صدد است با استفاده از مدل BI که ابزار کنترلی جدید و پیشرفته در اکتشاف و بهره‌برداری از داده‌های عظیم پرواز، پایگاه داده هوشمند و هم‌چنین ابزار مانیتورینگ، ترکیب با شبکه بازگشتی LSTM، پلتفرم نوین و کارآمد (BI.M-LSTM) جهت تجزیه و تحلیل داده‌های ایمنی فاز لندینگ و پیش‌بینی ریسک را نخستین بار در جهان ارائه دهد.

است منجر به لندینگ سخت، سقوط چرخ لندینگ، ضربه به دم یا در حالت بدتر، خارج شدن از باند گردد.

فاصله برخاست / لندینگ هواپیما یک پارامتر مهم به عنوان نتیجه تجزیه و تحلیل عملکرد برای ارزیابی ریسک است. (Hush, Li et al, 2023)

پرواز و گزارش‌های حادثه، به منظور شناسایی عوامل موثر در بروز حوادث، بسیار حائز اهمیت است. با پیشرفت‌های فناوری یادگیری عمیق و شبکه‌های عصبی بازگشتی مانند LSTM، امکان تحلیل داده‌های پیچیده سری زمانی و پیش‌بینی ریسک‌های احتمالی در این مرحله فراهم شده است. این مقاله با بهره‌گیری از ترکیب مدل هوشمند BI که ابزاری پیشرفته



شکل ۲. فرایند پرواز مرحله ابروج و لندینگ (بر اساس مدل هوش لای لی، ۲۰۲۳)

۳- روش پژوهش

حوادث لندینگ را تشکیل می‌دهند. انتخاب شد. انتخاب تأثیرگذارترین پارامترها برای اطمینان از ایجاد یک مدل قدرتمند و مقیاس پذیر حیاتی است. با انجام انتخاب ویژگی داده‌ها یا پارامترهایی که نامربوط هستند نادیده گرفته می‌شوند تا به بهبود دقت و کاهش هزینه محاسباتی در مرحله پیش‌بینی کمک کند. در این میان ۵ دسته مهم، عوامل انسانی، هواپیما، خط‌مشی شرکت، آب و هوا و فرودگاه می‌شوند، شناسایی شد. (حوادث ناشی از عوامل نادر در این پژوهش در نظر گرفته نمی‌شوند) دیتاست از لینک <https://zenodo.org> به دست آمد.

تحلیل داده برای تفسیر مجموعه داده‌های پیچیده برای کشف الگوها، روندها و همبستگی است. ترکیبی از منابع داده در بهبود قابل توجهی در نتایج پژوهش یادگیری ماشین به پیش‌بینی دقیق کمک کند. (Singe, et al, 2012)

۳-۱- داده‌ها

داده‌های خام پرواز از دیتاست استاندارد سال ۲۰۱۹ تا ۲۰۲۰ مربوط به داده پرواز گذشته حوادث پروازی گذشته که منجر به سانحه شده بود، از یک فرآیند چند مرحله‌ای مطابق با انکس شماره ۱۹ ایکائو، جمع‌آوری و پردازش شد. تعداد ۱۵ عامل پرتکرار با فراوانی زیاد که حدود ۹۵ درصد از کل

جدول شماره ۱. ویژگی داده‌های پرواز فاز پروچ و لندینگ

منبع	توصیف	ویژگی	
تسوینگ چینا (۲۰۲۳)	مرحله نزدیک شدن به باند لندینگ ایمن مدتی قبل از touchdown آغاز می‌شود. به عنوان اولین خط دفاعی در جلوگیری از خارج شدن از باند	Approach Unstable	۱
هوشو یای لی (۲۰۲۳)	ارتفاع زیاد لندینگ منجر به سرعت هوایی و سرعت زمینی بالا در باند و کنترل سرعت آن	landing / height	۲
آیسا (۲۰۲۴)	سرعت هوا در طول نزدیک شدن به باند و سرعت هوای فرود (VREF) سرعت هوا، را متوقف کند.	landing / airspeed	۳
چانگ فن (۲۰۲۳)	وزن ناخالص هواپیما بر فاصله فرود یکی از موارد اصلی تعیین کننده فاصله فرود است	weight calculation error	۴
میرزون لوری (۲۰۲۳)	فواصل AFM/POH بر اساس یک نقطه تماس	landing / touchdown	۵
یحیوی و همکاران (۲۰۲۴)	ترمز معکوس موتورها و زمان انجام دقیق آن بر اساس محاسبه و تصمیم درست خلبان	Reverser	۶
جینگ لی (۲۰۲۲)	ارتفاع بیش از حد از آستانه باند فرود بیش از ۵۰ فوت	height over the runway	۷
جانگ فنگ (۲۰۲۳)	فلپ‌های در حال نزدیک شدن به باند فرودگاه، ارتفاع کم کند و فرود شیب‌دار را فراهم می‌کند.	Flaps Control	۸
جمال و همکاران (۲۰۲۵)	سرعت وزش باد کنونی در فرودگاه و هم چنین جهت وزش باد در باند	wind blow	۹
آیسا (۲۰۲۴)	وضعیت باند فرودگاه در حالت فرود هواپیما	runway	۱۰
تسوینگ چینا (۲۰۲۳)	وضعیت ظاهری چرخ و باز شدن آن	Tire failure	۱۱
جینگ لی (۲۰۲۲)	دمای هوای فرودگاه بر اساس سانتی گراد	Temperature	۱۲
جانگ فنگ (۲۰۲۳)	توان موتور در موقع فرود	Engine	۱۳
یی لین (۲۰۲۰)	محاسبه زمانی پرواز برای رسیدن به مقصد	Trophic	۱۴
کول پاول (۲۰۲۴)	استفاده نادرست خلبان از چک لیست	Pilot-in- command supervision	۱۵

۳-۲- تحلیل داده

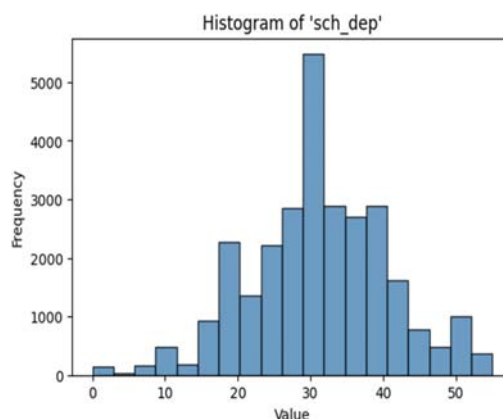
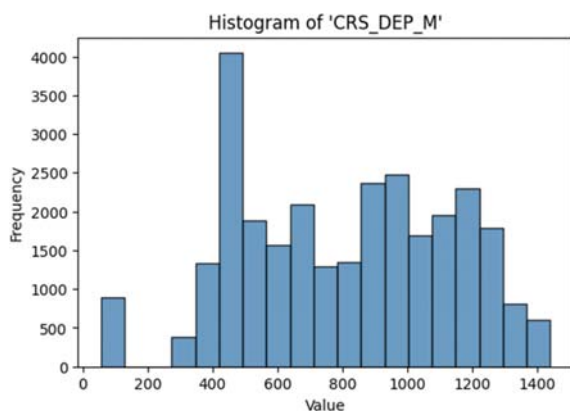
این بخش به تحلیل برخی از داده‌های پارامترهای پرواز لندینگ می‌پردازد. زاویه $pitch$ و زاویه حمله بیانگر عملیات خاص فرود است که توزیع آن به صورت نمودار هیستوگرام نشان شده است. در این پژوهش، پس از انجام پیش‌پردازش و پاکسازی داده‌های سری‌زمانی پرواز، از حدود ۲۸۳۲۳ رکورد داده، ۷۰ درصد برای آموزش مدل و ۳۰ درصد برای ارزیابی و اعتبارسنجی آن مورد استفاده قرار گرفته است. بر اساس مرور ادبیات و مشاوره با کارشناسان هوانوردی، ۱۵ ویژگی کلیدی مرتبط با ایمنی لندینگ انتخاب شد. این ویژگی‌ها در سه گروه اصلی طبقه‌بندی گردیدند:

-عوامل محیطی (مانند سرعت باد جانبی، دما، دید افقی)

-عملکرد هواپیما (مانند سرعت عمودی تماس، زاویه فلپ، توان موتور)

-عوامل عملیاتی (مانند نقطه تماس با باند، طول مسیر استفاده‌شده، وضعیت ترمز معکوس)

شکل ۱ توزیع داده‌های رویدادهای پارامترهای پرواز در طول فرود هواپیما را نشان می‌دهد، تغییرات به طور چشمگیری در فاصله زمانی قبل و بعد از لندینگ رخ داده است، که به طور کامل پتانسیل یادگیری عمیق را از نظر پارامترهای پرواز تایید می‌کند. در میان این پارامترها، تغییر sch_dep پارامتر کلیدی تشخیص فرود پایدار است.



شکل ۱. توزیع رویدادهای تاثیر گذار بر لندینگ

۳-۳- مدل LSTM

شبکه LSTM یک نوع خاص از RNN است که می‌تواند اطلاعات وابسته به مدت طولانی را یاد بگیرد و برای طبقه‌بندی، پردازش و پیش‌بینی سری‌های زمانی مناسب است. این مدل می‌تواند چندین لایه از واحدهای محاسباتی پنهان با عملکرد بالا را آموزش دهد. LSTM‌ها از یک حالت سلولی استفاده می‌کنند که اطلاعات گذشته را نگه می‌دارد و سه گیت که حالت سلول را به روز، پیش‌بینی

و محاسبه می‌کند. مدل ۵ لایه‌ای BI پیش‌بینی و تحلیل کسب‌وکار مورد استفاده قرار می‌گیرد. (Jaary, et al, 2022) (نگ اریس و همکاران، ۲۰۲۳) در یادگیری نظارت شده (طبقه‌بندی یا رگرسیون) از تارگت‌ها در مرحله آموزش مدل استفاده می‌شود در مسائل رگرسیون تارگت مقدار واقعی خروجی پیش‌بینی شده است. (Zho, et al, 2020)

۳-۴- ETL

این لایه بر اساس معماری BI شامل سه مرحله مهم در فرایند آماده سازی داده است. فرآیند پیش‌پردازش داده‌ها شامل پاکسازی داده‌ها، تبدیل داده‌ها، نرمال‌سازی و استانداردسازی داده‌ها است. در مرحله اول، ۱۷ ویژگی به عنوان ورودی به شبکه LSTM استفاده شد تا

عمل کاهش ابعاد سیگنال ورودی اولیه را انجام دهد. بنابراین، ورودی می‌تواند به عنوان یک ماتریس داده‌های پرواز مشخص شود و به صورت زیر نشان داده می‌شود.

$$x = \begin{bmatrix} p_{t-n}^1 & p_{t-n+1}^1 & \dots & p_{t-1}^1 & p_t^1 \\ p_{t-n}^2 & p_{t-n+1}^2 & \dots & p_{t-1}^2 & p_t^2 \\ p_{t-n}^3 & p_{t-n+1}^3 & \dots & p_{t-1}^3 & p_t^3 \\ \vdots & \vdots & \dots & \vdots & \vdots \\ p_{t-n}^{15} & p_{t-n+1}^{15} & \dots & p_{t-1}^{15} & p_t^{15} \end{bmatrix}$$

می‌شود. از بین مدل‌های یادگیری مختلف، مدل یادگیری عمیق به علت اینکه هر یک از داده‌های پرواز وابسته به ورودی‌های ماقبل خود هستند و نیاز به نوعی حافظه دارند. شبکه‌های مدل یادگیری عمیق برای بهینه‌سازی انتخاب شد.

شبکه عصبی مدل یادگیری عمیق از چندین گیت و متغیر تشکیل شده است. توسط برنامه نویسی پایتون کراس تنسورفلو مدل سازی شد. به این صورت بیان می‌شود.

جدول ۲. معماری شبکه LSTM چند لایه

پارامتر	خروجی	لایه	
۸۳۴۵۸	(۱ و ۱۲۸)	LSTM_1	۱
۴۹۴۰۸	(۱ و ۶۴)	LSTM_2	۲
۶۵	۱	Dance	۳
	۱۳۳۹۳۹	کل	
	۱۳۳۹۲۹	پارامترهای آموزش	

در این مطالعه از ۲ لایه LSTM به ترتیب لایه وروی با ۳۴ نورون، لایه اول ۱۲۸ نورون، لایه دوم ۶۴ نورون، یک لایه خروجی با ۶۵ نورون استفاده شد. این الگوریتم قادر به یادگیری وابستگی‌های بلند مدت هستند، در حالی که RNN ساده فقط وابستگی‌های کوتاه مدت را یاد می‌گیرند. نورون‌های LSTM توسط گیت فراموشی f_t تعیین می‌کند چه مقدار اطلاعات از حالت سلول قبلی باید حفظ شود به صورت زیر محاسبه می‌شود:

$$f_t = \sigma(w_t \times [h_{t-1}, x_t] + b_f) \quad (2)$$

w_t ماتریس وزن دروازه فراموشی، b_f شرط بایاس دروازه فراموشی و σ تابع سیگموئید است.

سپس، گیت ورودی به همراه یک لایه \tanh با هم اطلاعات جدیدی را که باید در حالت سلول ذخیره شود انتخاب می‌کنند گیت ورودی i_t میزان اضافه شدن به حالت سلول در هر مرحله زمانی را تنظیم می‌کند. به صورت زیر محاسبه شد.

$$i_t = \sigma(w_i \times [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{c}_t = \tanh(w_c \times [h_{t-1}, x_t] + b_c) \quad (4)$$

در این ماتریس، درایه p_{t-n}^{15} نشان دهنده مقدار پارامتر پرواز (ارتفاع پرواز) در $timestep (t-n)$ است. این ماتریس به عنوان یک بردار ورودی بیان می‌شود که هر عنصر آن یک بردار از پارامترهای پرواز را نشان می‌دهد. در یک $timestep$ بعدی، یک دنباله چند متغیره از پارامترهای پرواز با $n timestep$ گذشته وابسته است. داده‌ها از نظر مقادیر گمشده، نویز و ناهنجاری بررسی و اصلاح شدند. مقادیر گمشده با روش میانگین‌گیری وزنی جایگزین و داده‌های پرت با استفاده از تحلیل آماری حذف یا اصلاح گردیدند. هدف از پاکسازی داده‌ها حذف داده‌های غیرطبیعی جهت به دست آوردن اطلاعات اندازه‌گیری و ویژگی مرتبط دقیق داده‌هاست. آماده‌سازی داده‌ها برای الگوریتم‌های یادگیری ماشین، به دو روش تبدیل داده استفاده شد: رمزگذاری داده و نرمال‌سازی داده. در رمزگذاری داده، ویژگی‌های طبقه‌ای به نمایش عددی تبدیل شدند و در نرمال‌سازی داده، داده‌های عددی مانند سرعت هواپیما، بر اساس محدوده پویای خود، بین ۰ تا ۱ نرمال‌سازی شد تا ویژگی عددی پروازهای مختلف بر مقیاس‌ها سازگار بوده و هم‌چنین بر مدل پیش‌بینی تأثیر مشابهی داشته باشند.

$$X' = \frac{x - X_{min}}{X_{max} - X_{min}} \quad (1)$$

کل داده‌ها پرواز ۲۸۸۱۳ به دو دسته داده‌های آموزشی و داده‌های آزمایشی تقسیم شدند. داده‌های آموزشی ۲۰۱۶۹ شامل ۷۰ درصد از کل داده‌ها برای فرایند آموزش جهت محاسبه گرادیان و بهینه‌سازی پارامترها مورد استفاده قرار گرفت و تعداد ۸۶۴۴ یعنی ۳۰ درصد از داده‌ها به داده‌های آزمایشی مدل به طور تصادفی اختصاص یافت.

۳-۵- معماری لایه LSTM

شبکه‌های عصبی بازگشتی به دلیل قابلیت مدل‌سازی داده‌های توالی در زمینه یادگیری ماشین توسعه یافته شده است. در این شبکه، اطلاعات از طریق یک زنجیره از گره‌های متصل، با پردازش داده‌های توالی ورودی جهت تکامل توالی منتقل

$$h_t = O_t \times \tanh(C_t) \quad (۷)$$

در اینجا، ماتریس وزن دروازه خروجی و b_c شرط بایاس سلول حافظه است. ویژگی‌ها از این پارامترها استخراج می‌شوند. شبکه عصبی LSTM از ۳ لایه و یک لایه خروجی رگرسیون تشکیل شده است. لایه اول یک نرم‌سازی دسته‌ای با ۵۰ واحد و یک تابع فعال سازی \tanh است. لایه خروجی یک لایه تک نورونی و یادگیری با استفاده از تابع بهینه‌ساز Adam (کینگ ما، ۲۰۱۴) صورت گرفت.

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (۵)$$

در اینجا، w_i ماتریس وزن دروازه ورودی، w_c نشان‌دهنده وزن حافظه و b_i شرط بایاس دروازه ورودی است. کنترل دروازه‌های فراموشی و خروجی به مدل LSTM امکان می‌دهد تا از اطلاعات گذشته و اطلاعات برای پیش‌بینی در لحظه فعلی استفاده کند. خروجی نهایی مدل نتیجه ضرب دروازه خروجی در لایه \tanh است، به صورت زیر محاسبه شد:

$$O_t = \sigma(w_o \times [h_{t-1}, x_t]) + b_c \quad (۶)$$

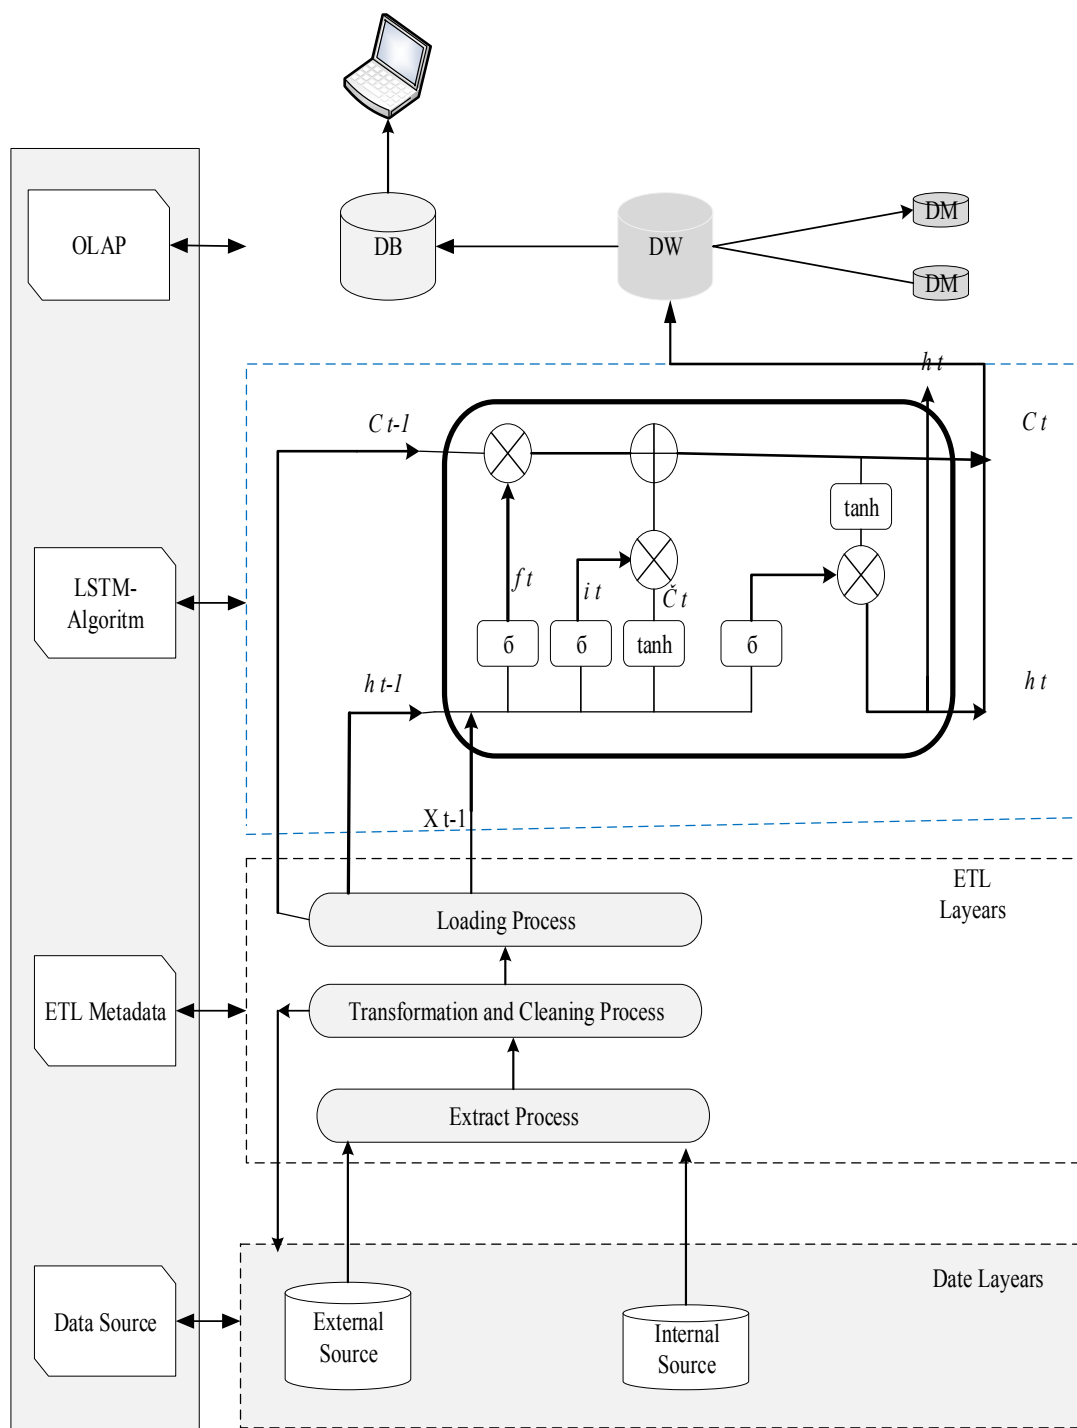
۳-۶- مدل پیشنهادی B.I.M-LSTM

می‌گردد در این مرحله اکتشاف داده‌های از میان انبوه داده وارد شده، انجام می‌شود و سپس دسته‌بندی شده تا در مدل یادگیری عمیق مورد استفاده قرارگیرد و خروجی آن به لایه انبار داده تحلیلی اطلاعات وارد و ذخیره می‌شود. متا دیتاها اطلاعاتی در مورد تمام داده‌ها و مهم‌تر از همه تغییرات داده‌ای، تغییرات قوانین جهت پشتیبانی و دسته‌بندی موارد ایمنی نگهداری و بروزرسانی می‌کنند. به طوری که شکل ۸ نشان می‌دهد، آخرین لایه ابزاری قدرتمند اطلاعات را در فرمت‌های مختلف به خدمه پرواز و کادر به صورت سریع و دقیق نشان می‌دهد.

شکل ۴ ساختار مدل پیشنهادی B.I.M-LSTM برای پیش‌بینی ریسک ایمنی پرواز در حالت لندینگ مورد استفاده قرار می‌گیرد نشان می‌دهد: BI به منظور مصورسازی داده‌ها، شناسایی روندها و تهیه گزارش‌های تحلیلی اولیه مورد استفاده قرار گرفت و LSTM برای مدل‌سازی روابط پیچیده زمانی و پیش‌بینی وقوع رویدادهای ناخواسته در لندینگ به کار رفت منابع داده‌ای از لایه اول وارد مدل می‌شود به لایه دوم که فرایند پردازش اولیه انبوه داده‌های پرواز هواپیما، شناسایی، پاکسازی، خلاصه‌سازی، حذف داده زاید، ادغام (Baars, et al,2008) است، منتقل

جدول ۵. تعریف لایه‌ها، ورودها مدل B.I.M-LSTM

لایه	نام لایه	ورودی	فرایند	نقاط قوت
۱	لایه داده	داده ورودی مدل	داده‌ها از منابع پایگاه داخلی و خارجی وارد مدل می‌شود	پروازی از داده‌های عظیم موجود،
۲	ETL	لایه داده	استخراج داده‌ها، ادغام، حذف، پاکسازی، خلاصه سازی انجام شده و خروجی آن وارد مدل LSTM	استخراج داده‌های سازمان‌دهی طبقه‌بندی، ذخیره و پردازش داده
۳	LSTM	ETL	داده‌های هواپیمایی وابسته به گذشته از نوع سری زمانی است و شبکه LSTM برای پیش‌بینی سری‌های زمانی مناسب است، این الگوریتم جهت آموزش استفاده شد	الگوریتم شبکه عصبی عمیق LSTM، الگوریتم قوی درکشف الگوی جدید پیش‌بینی ریسک ایمنی
۴	پایگاه داده تحلیلی	LSTM	ذخیره سازی داده‌ها برای الگو سازی	دیتاست بروز برای یادگیری
۵	لایه متا دیتا	از همه لایه ها	متا دیتاها اطلاعاتی در مورد تمام داده‌ها و مهم‌تر از همه تغییرات داده‌ای، تغییرات قوانین جهت پشتیبانی و دسته‌بندی موارد ایمنی نگهداری و بروزرسانی می‌کنند.	ابزار قدرتمند بروزرسانی
۶	لایه مانیتورینگ	پایگاه داده تحلیلی	در این قسمت خروجی شبکه بصورت لحظه‌ای مانیتور شده و در اختیار مدیران و خدمه پرواز قرار می‌گیرد.	داشبورد مورد استفاده خلبان



شکل ۴. مدل پیشنهادی BIM-LSTM بهینه‌سازی لندینگ

در رابطه فوق n نشان دهنده تعداد مشاهدات، مقادیر اندازه‌گیری شده و y نشان‌دهنده مقدار پیش‌بینی شده است. قابلیت پیش‌بینی سیستم توسعه داده شده توسط درصد میانگین مطلق خطای سیستم که نشان دهنده انحراف بین مقادیر تجربی و پیش‌بینی شده است به صورت رابطه زیر محاسبه شد.

(۹)

$$MAPE \frac{1}{n} \sqrt{\sum_{i=1}^n \frac{y - \bar{y}}{y}}$$

در رابطه فوق نیز n نشان‌دهنده تعداد مشاهدات، y مقادیر اندازه‌گیری شده و نشان دهنده مقدار پیش‌بینی است. این رابطه خطای نسبی انحراف بین مقادیر پیش‌بینی شده و داده‌های اندازه‌گیری شده را طوری محاسبه می‌کند که پارامترهای آزاد شبکه (وزن‌ها و بایاس‌ها) توسط الگوریتم‌های آموزش و بر اساس داده‌های آموزشی (شامل بردارهای ورودی و هدف) به گونه‌ای بهینه شوند تا مقدار خطای بین خروجی شبکه و پارامتر هدف به حداقل مقدار ممکن خود برسد.

است. این شاخص برابر با میانگین مقادیر مطلق اختلاف بین تخمین‌گر و مقدار واقعی است.

جدول ۳. میزان خطای یادگیری

تست	آموزش	پارامتر
۱۳/۱۷	۱۴/۰۱	خطای یادگیری
۶/۱۲۵	۶/۱۴۸	RMSE
	۵/۱۲۱	MEPA
۸۴۹۷	۱۹۸۲۶	کل داده پرواز (۲۸۳۲۳)

جدول ۳ میزان خطای یادگیری در هر یک از گروه داده‌های آموزشی، آزمایشی را نشان می‌دهد، بر این اساس چون مقادیر این شاخص به عدد صفر نزدیکتر است، نشان دهنده میزان کمتر خطا گروه داده است و درصد اطمینان مدل قابل قبول است.

شکل ۴ نشان می‌دهد: منابع داده‌ای از لایه اول وارد مدل می‌شود به لایه دوم که فرایند پردازش اولیه انبوه داده‌های پرواز هواپیما، شناسایی، پاکسازی، خلاصه‌سازی، حذف داده زاید، ادغام (بارس و همکاران، ۲۰۰۸) است، منتقل می‌گردد در این مرحله اکتشاف داده‌های از میان انبوه داده وارد شده، انجام می‌شود و سپس دسته‌بندی شده تا در مدل یادگیری عمیق مورد استفاده قرارگیرد. و خروجی آن به لایه انبار داده تحلیلی اطلاعات وارد و ذخیره می‌شود. متا دیتاها اطلاعاتی در مورد تمام داده‌ها و مهم‌تر از همه تغییرات داده‌ای، تغییرات قوانین جهت پشتیبانی و دسته‌بندی موارد ایمنی نگهداری و بروزرسانی می‌کنند. آخرین لایه ابزاری قدرتمند (OLAP) اطلاعات پرواز را در فرمت‌های مختلف به خدمه پرواز و کادر فرودگاهی به صورت سریع و دقیق نشان می‌دهد.

به منظور بررسی عملکرد شبکه، از میانگین مربعات خطا^۱ (RMSE) به عنوان معیاری برای سنجش دقت نتایج مدل پیشنهادی استفاده شد. عملکرد مدل با استفاده از شاخص‌هایی نظیر دقت حساسیت و معیار سنجیده شد.

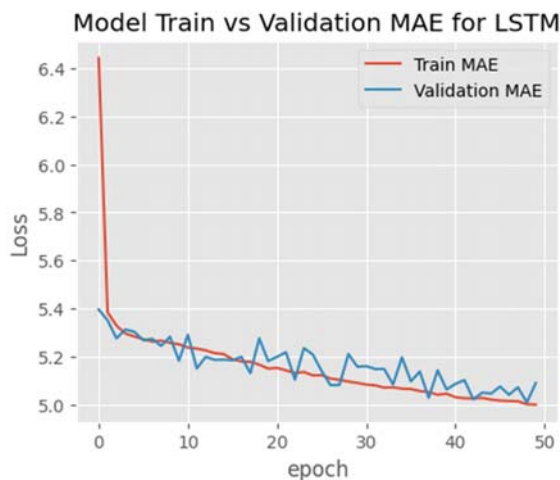
$$RMSE \frac{1}{n} \sqrt{\sum_{i=1}^n (y - \bar{y})^2}$$

(۸)

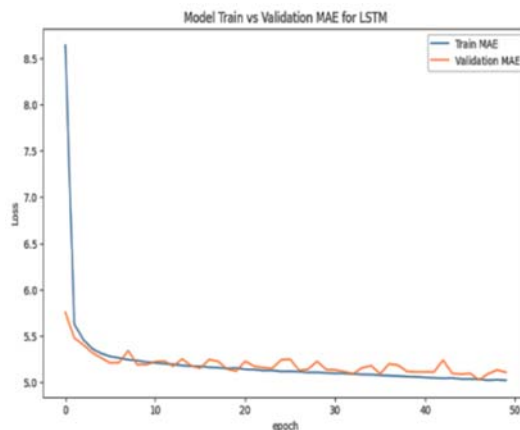
۴- یافته‌ها

جهت یادگیری از یک مدل نوع یادگیری عمیق (RNN-LSTM) نظارت‌شده، خروجی داده‌ها تعیین پیش‌بینی ریسک و پیوسته است. از تابع رگرسیون خطی استفاده می‌گردد.

کارایی مدل پیشنهادی با LSTM در طول فرآیند آموزش، تعدادی از پارامترها، مانند اندازه دسته، تابع فعال‌سازی، تعداد واحدهای پنهان، نوع بهینه‌ساز و تعداد اپوک تنظیم شدند تا مدل بهینه ممکن به دست آید. تابع بهینه‌ساز برای کمینه‌کردن تابع loss انتخاب شد. در طول فرآیند آموزش، تعدادی از پارامترها، مانند اندازه دسته، تابع فعال‌سازی، تعداد واحدهای پنهان، نوع بهینه‌ساز و تعداد اپوک (۵۰) تنظیم شدند تا مدل بهینه ممکن به دست آید. تابع بهینه‌ساز برای کمینه‌کردن تابع loss انتخاب شد. نمودار MAE یا خطای میانگین مطلق یک شاخص برای اندازه‌گیری میزان خطای یک تخمین‌گر نسبت به مقدار واقعی



شکل ۳. نمودار خطای میانگین مربعات



شکل ۲. نمودار خطای میانگین مطلق

ارزیابی در راستای حفظ شبکه مورد استفاده قرار می‌گیرد. روال آموزش تا زمانی ادامه می‌یابد که خطای شبکه در مورد شبکه ارزیابی کاهش نشان دهد. بدین ترتیب از بیش برآزش شبکه بر روی مجموعه آموزشی جلوگیری می‌شود. مقادیر خطای RMSE مدل را نشان می‌دهد کمترین مقدار به دست آمده از رابطه (۹) برای میانگین مربعات خطا برابر با $6/125$ در اپوک ۵۰ نقطه بهینه مدل است.

بر اساس نمودار (۲) چون مقدار شاخص خطای میانگین مطلق کمتر است، نشان دهنده دقت بیشتر تخمین‌گر است و خطای آن برابر $5,126$ است. همانطور که در این نمودار ملاحظه می‌شود خطای میانگین مربعات شبکه از یک مقدار آغاز شده و رفته رفته کاهش یافته است. این بدان معناست که روال یادگیری شبکه دارای پیشرفت می‌باشد. نمودار (۳) دارای دو خط است که بردارهای ورودی و هدف بصورت تصادفی به دو مجموعه آموزشی (۷۰٪) و آزمایشی (۳۰٪) تقسیم شده است. مجموعه

جدول ۶. مقایسه مدل حاضر با مدل‌های دیگر

مطالعه	هدف پژوهش	مجموعه داده	الگوریتم‌ها	عملکرد
ربینسون (۲۰۲۰)	اطلاعات از گزارش‌های رویدادها	گزارش ایمنی هوانوردی ۷,۴۸۴	کشف روابط مفهومی	شناسایی چندین عامل موثر در هر رویداد
شی ۲۰۲۰	از یادگیری ماشین برای شناسایی عوامل اصلی	گزارش رویداد ایمنی هوانوردی ۱۶۸,۲۲۷	یادگیری عمیق	شناسایی عامل علیت اصلی در هر رویداد
دانگ (۲۰۲۱)	عامل اصلی و عامل جانبی موثر عامل علی	گزارش رویداد ایمنی هوانوردی ۱۸۱,۶۵۱	شبکه‌های عصبی عمیق بازگشتی	استخراج اطلاعات ساختار یافته
هانگ ۲۰۲۲	تجزیه و تحلیل داده	تحلیل داده‌های پرواز	PS-AE-LSTM الگوی نو آورانه	مقدار مجذور خطا میانگین $RMSE = 13/51$ مدل با دقت $84/45$ درصد
مطالعه حاضر ۲۰۲۴	بهینه سازی فرایندهای ایمنی پرواز	تحلیل داده‌های پرواز ۲۸۸۱۳	الگوی نوآورانه B.I.M-LSTM	مقدار مجذور میانگین مربعات خطا $(RMSE)=6/125$ مدل با دقت $93/875$ درصد

۵- نتیجه‌گیری

داده‌ها، در تجزیه و تحلیل ایمنی پرواز را ممکن می‌سازد. به‌طور پیوسته در صورت تغییر، آن را بروزرسانی کرده و به صورت لحظه‌ای نشان می‌دهد. این مدل از شبکه عصبی LSTM در تخمین پارامترهای متناسب با سیستم نظارت و ایمنی پرواز از جمله سرعت هواپیما در باند فرودگاه استفاده می‌کند. همبستگی بالای منحنی‌های تخمین با منحنی‌های واقعی بیانگر این است که خطا به نظر غیرقابل توجه است و ریسک ایمنی پرواز با خطای ۶,۱۲۵ درصد بهتر از مدل FSM که در موارد اضطراری سیستمی بسیار ناکارآمد است (بلانچاندران، ۲۰۱۵) (یوها و جی، ۲۰۲۲)، ارزیابی می‌شود روش پیشنهادی پیو وانگ (۲۰۲۳) به صورت موثر دارای خطای نسبی متوسط ۸ درصد و مدل هانگ (۲۰۲۲) خطای نسبی ۱۳,۵۱ است. پس این مدل نسبت به سایر مدل‌های عمقی عملکرد بهتری (دقت مدل برابر ۹۳,۴۱) نشان می‌دهد.

این الگو با راهبردی قابل اطمینان به خدمه پرواز در ایستگاه زمینی و هوایی در راستای کنترل پارامترهای مهم ریسک ایمنی پرواز آخرین مرحله پرواز از جمله، سرعت هواپیما، ارتفاع پرواز، کنترل ترمزها و مهم‌تر از همه کنترل از دست رفتن پرواز جهت جلوگیری از خارج شدن از باند پرواز کمک می‌کند. استفاده از این پلتفرم نوین می‌تواند به بهبود فرآیندهای نظارت و مدیریت ریسک در فاز لندینگ کمک قابل توجهی کند.

مقاله حاضر مدل پیش‌بینی ریسک ایمنی پرواز فاز لندینگ با استفاده از الگوریتم نوآورانه B.I.M-LSTM برای نخستین بار در جهان ارائه می‌دهد. یادگیری عمیق یک روش مهم برای تحلیل و تفسیر داده‌های پیچیده است که در زمینه‌های مختلف کاربرد دارد. الگوهای حرکت هواپیما در طول پرواز جهت کاهش ریسک احتمالی است که برای کاربردهای مختلف مانند ارزیابی عملکرد خدمه پرواز، تشخیص ریسک خطاها و حوادث، بهبود ایمنی و کارایی پرواز و آموزش شبیه‌سازی مفید است. استفاده از شبکه عصبی بازگشتی برای کشف قوانین تغییرات داده موثر است. نتایج الگوریتم فرا ابتکاری B.I.M-LSTM در حل مسئله FSM در تحلیل داده‌های پرواز موجود در این پژوهش پس از ۵۰ بار تکرار به صورت جداگانه با شرایط یکسان نشان می‌دهد که جواب بهتری نسبت به الگوریتم‌های مشابه مانند PS-AE-LSTM دارد و هم از نظر میانگین و هم بهینه‌سازی تابع هدف شرایط بهتری نیز دارد.

مدل B.I.M-LSTM به دلیل برخورداری از ابزارهای پیشرفته بهینه‌سازی مشکل استخراج، اکتشاف، دسته‌بندی انبوه داده‌ای پرواز را حل می‌کند. و منجر به کاهش هزینه سرسام آور بخش تحلیل داده‌ای می‌شود. در بیان مساله چالش نیاز به افزایش مستمر شناسایی ریسک جهت بهبود تحلیل داده‌های ایمنی پرواز وجود داشت، لایه متا دیتا مدل زمینه قابلیت ذخیره‌سازی و پردازش

۶-مراجع

-Balachandran, S and Ella. M. Atkins (2015). Flight Safety Assessment and anagement for Takeoff Using Deterministic Moore Machines, *Journal of Aerospace Information Systems*, Vol. 12, No. 9.
-Borst, C., Grootendorst, F. H., Brouwer, D. I. K., Bedoya, C., Mulder, M., and van Paassen, M. M., (2013). Design and Evaluation of a Safety Augmentation System for Aircraft. *Journal of Aircraft*, Vol. 51, No. 12-22.
doi:10.2514/1.C031500
-Chongfeng Li, Ruishan Sun , Xing Pan (2023). Takeoff runway overrun risk assessment in aviation safety based on human pilot behavioral characteristics from real flight data *Safety Science* 158, 105992.

-Aleksandrs Bitiņš, Ruta Bogdane, Vladimir Shestakov, Anastasija Stepanova (2022). The oretical and Methodological approaches to The Information Base for an Airlines Flight Safety System, *Transactions on Aerospace Research* eISSN. Vol. 266, No. 1/2022, 75-83.
doi: 10.2478/tar-2022-0006
-Aysha S. Hameed, Bindu G . R, Srianish Vutukuri (2024). Approach and landing guidance using constrained model predictive static programming *Aerospace Science and Technology* 144 (2024) 108732.
-Baars, H. & Kemper, H.-G. (2008). Management Support with Structured and Unstructured Data: An Integrated Business Intelligence Framework, *Information Systems Management*, 25(2). 132-148.

doi: 10.3934/era.2023005

-JuanFang, QiangangZheng, ChangpengCai, HaoyinChen, HaiboZhang (2023). Deep reinforcement learning method for turbofan engine acceleration optimization.

-Lai H-Y lee B. (2017). Unstable approach: intervention and prevention. In: Transdisciplinary engineering: a paradigm shift: proceedings of the 24th ISPE Inc. *International Conference on Transdisciplinary Engineering*, July 10–14, IOS Press.

-Mickael Rey, Daniel Aloise, François Soumis, Romanic Pieugueu (2021) A data-driven model for safety risk identification from flight data analysis. *Transportation Engineering* 5, 100087.

-Ng Iris, Sarasvathi Nagalingham (2023). Implementation of Business Intelligence Solution for United Airlines. (IJACSA) *International Journal of Advanced Computer Science and Applications*, Vol. 14, No. 1.

-PeiyaoWang, Mingxin Yu1, Guang Yan1, Jiabin Xia, Jiawei Liu1 and Lianqing Zhu (2023). A deep learning-based method for calculating aircraft wing loads Measurement and Control 1–13. The Author(s) 2023 Article reuse guidelines. [sagepub.com/journals-permissions](https://www.sagepub.com/journals-permissions).

doi:

177/00202940221145971journals.sagepub.com/home/mac

-Singh, G.; Singh, J. Prabha, C. (2022). Data visualization and its key fundamentals: A comprehensive survey. In *Proceedings of the 2022th International Conference on Communication and Electronics Systems (ICCES)*, Coimbatore, India, 22–24 June.

-Tahsin Sejat Saniat, Tahiat Goni, Shaikat M. Galib (2020). lstm recurrent neural network assisted aircraft stall prediction for enhanced situational awareness [arxiv:2012.04876v1](https://arxiv.org/abs/2012.04876v1) [cs.lg] 9 dec.

-Tejas Puranik, Evan Harrison, Sanggyu Min, Hernando Jimenez, and Dimitri Mavris (2023). General Aviation Approach and Landing Analysis using Flight Data Records Downloaded by Ecole Technologie Supérieure (ETS) on December 31.

-Yi Lin, Linjie Deng, Zhengmao Chen, Xiping Wu, Jianwei Zhang, and Bo Yang (2020). A Real-Time ATC Safety Monitoring framework using a Deep Learning Approach *IEEE* Vol. 21, No. 11, Nov.

-Zhi lu et al (2018). An Architecture of system of system (SoS) for Commercial flight Security in 5G *5th international confererancr on system and informatics (ICSAL 2018)*.

-Zhu, D.; Wang, Y.; Zhang, F. (2022). Energy Price Prediction Integrated with Singular Spectrum Analysis and Long Short-Term Memory Network against the Background of Carbon Neutrality. *Energies*, 15, 8128.

-D. P. Kingma and J. Ba, (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.

-Eduardo Gallo(2021) Quasi Static Atmospheric Model for Aircraft Trajectory Prediction and Flight Simulation Systems and Control (eess.SY) **arXiv:2101.10744v1 [eess.SY] 26 Jan 2021**

-F. A. Gers, J. Schmidhuber, and F. Cummins, (1999). Learning to forget: Continual prediction with lstm.

-Gabriel Jarry, Daniel Delahaye, Eric Féron.(2020) Approach and landing aircraft on-board parameters estimation with LSTM networks. AIDA-AT 2020, 1st conference on Artificial Intelligence and Data Analytics in Air Transportation, Feb 2020, Singapore, *Singapore*. ISBN: 978-1-7281-5381-0.

-Govindarajan, N., De Visser, C., Van Kampen, E., Krishnakumar, K., Barlow, J., and Stepanyan, V., (2015). Optimal Control Framework for Estimating Autopilot Safety Margins. *Journal of Guidance, Control, and Dynamics*, Vol. 38, No. 7, 1197–1207.

doi:10.2514/1.G000271

-Guo Y, Sun Y (2020) Flight safety assessment based on an integrated human reliability quantification approach. *PLoS ONE* 15(4): e0231391.

doi.org/10.1371/journal.pone.0231391

-Habler, Edan, Bitton, Ron & Shabtai, Asef (2021). Evaluating the Security of Aircraft Systems [arXiv: 2209.04028v1](https://arxiv.org/abs/2209.04028v1) [cs.CR] 8 Sep 2022.

-Hong Sun, Fangquan Yang, Peiwen Zhang, Yang Jiao and Yunxiang Zhao (2023). An Innovative Deep Architecture for Flight Safety Risk Assessment Based on Time Series Data Computer Modeling in Engineering & Sciences.

doi: 10.32604/cmcs.2023.030131

-Hsueh-Yi Lai (2023). Breakdowns in team resilience during aircraft landing due to mental model disconnects as identified through machine Reliability Engineering and System Safety 237, 109356.

-Jammal, P., Fischer, O. P., Mavris, D. N., & Wagner, G. (2025). Advancing Aviation Safety through Predictive Maintenance: A Machine Learning Approach for Carbon Brake Wear Severity Classification. *Aerospace*, 12(7), 602.

-Yahyavi, M., Toloie, A., Afsharkazemi, M., Radfar, R (2024) designing 30495/JIK.2024.23254an intelligent model to optimize to safety risk of the takeoff flight using B.I.M-LSTM.

-ICAO, Doc 9859, (2022). Safety management manual, 4th ed. Montréal, Quebec, Canada: *International Civil Aviation Organization (ICAO)*.

-Jing Lu, Longfei Pan, Jingli Deng, Hongjun Chai1, Zhou Ren1 and Yu Shi, (2022). Deep learning for Flight Maneuver Recognition: A survey *ERA*, 31(1): 75–102.

An Intelligent Model for Predicting Flight Safety Risk in the Landing Phase Using the BIM-LSTM

Mansour Yahyavi, .Ph.D., Student, Department of Information Technology Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran .

Abbas Toloie Ashlaghi, Professor, Department of Industrial Management, Science and Research Branch, Azad Islamic University, Tehran, Iran.

Mohammad Ali Afshar Kazemi, Professor, Department of Information Technology Management, Faculty of Management, Islamic Azad University, Tehran, Iran.

Reza Radfar, Professor, Department of Technology Management, Faculty of Management and Economic, Science and research branch, Islamic Azad University, Tehran, Iran.

E-mail: toloie@gmail.com

Received: May 2025- Accepted: August 2025

ABSTRACT

This paper presents an innovative model, **BIM-LSTM**, which combines the Business Intelligence (BI) algorithm with a Long Short-Term Memory (LSTM) recurrent neural network to predict flight safety risks during the landing phase for the first time worldwide. The landing phase is one of the most critical stages of flight, requiring high precision and control from the flight crew, as a significant portion of aviation accidents occur at this stage. The study employs supervised training of recurrent neural networks to estimate target safety parameters. The dataset consists of over 28,000 time-series flight records from a standard database covering 2019 to 2020. After cleansing and normalizing, safety risk parameters related to landing—such as airport weather conditions, aircraft configuration, air traffic, speed, and altitude—were selected. Due to the dependency of flight data on prior inputs and the need for memory, training was performed using the LSTM algorithm. The mean squared error after training was approximately 6.125%. Results indicate that the error rate is negligible, and the proposed model shows significantly higher reliability compared to similar models. The BIM-LSTM hybrid model accurately identifies high-risk factors and predicts the likelihood of undesirable events. These findings can contribute to improving pilot decision-support systems and enhancing safety protocols during the landing phase.

Keywords: Flight Safety Risk, Air Transportation, Landing, Model, Deep Learning, BIM-LSTM