



طراحی مدلی هوشمند جهت بهینه‌سازی ریسک ایمنی پرواز تیک آف با استفاده از B.I.M-LSTM

منصور یحیوی

دانشجوی دکتری تخصصی، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران
yahyavi@shariaty.ac.ir

عباس طلوعی اشلقی

استاد گروه مدیریت فناوری اطلاعات، دانشکده مدیریت، واحد علوم تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران (عهده دار مکاتبات)
toloie@gmail.com

محمد علی افشار کاظمی

استاد گروه مدیریت فناوری اطلاعات، دانشکده مدیریت، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران.
dr.mafshar@gmail.com

رضا رادفر

استاد گروه مدیریت فناوری اطلاعات، دانشکده مدیریت، واحد علوم تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران
radfar@gmail.com

تاریخ دریافت: ۱۴۰۲/۰۴/۲۳ تاریخ پذیرش: ۱۴۰۲/۰۶/۰۱

چکیده

مقاله حاضر، مدل جدیدی جهت بهینه‌سازی ریسک ایمنی تیک‌آف به عنوان مهم‌ترین و خطرناکترین فرایند پرواز، با استفاده از ترکیب الگوریتم BI و شبکه عصبی بازگشتی LSTM ارائه می‌دهد. هدف، آموزش یک شبکه عصبی موثر با رکوردهای داده سوانح هوایی گذشته برای پیش‌بینی پارامترهای ریسک ایمنی است. بدین منظور ۱۷ ویژگی ایمنی، مانند شرایط آب و هوایی، پیکربندی و آماده‌سازی هواپیما، اطلاعات پرواز و ترافیک هوایی بدست آمد. داده مربوطه از سال ۲۰۱۹ تا ۲۰۲۰ پس از انجام عملیات اکتشاف، خلاصه‌سازی، پاکسازی، نرمال‌سازی به تعداد ۲۸۸۱۳ رکورد داده انتخاب شد. به علت وابستگی داده‌های پرواز به ورودی‌های ما قبل خود و نیاز به نوعی حافظه، آموزش توسط الگوریتم یادگیری عمیق (LSTM) در محیط پایتون انجام گرفت. پس از یادگیری، خطای یادگیری حدود ۶ درصد و میانگین مربعات خطا حدود ۰/۱۱۶ بدست آمد. نشان می‌دهد، درصد خطا غیر قابل توجه و مدل پیشنهادی از اعتبار بالایی برخوردار است. هم‌چنین این مدل به دلیل برخورداری از ابزارهای پیشرفته از جمله ETL، متادیتا و مانیتورینگ لحظه‌ای مشکل اکتشاف و پاکسازی انبوه داده‌های پرواز را حل کرد و توانست مهم‌ترین عامل ریسک ایمنی (سرعت V1) را با دقت بالا پیش‌بینی کند. این الگو با راهبردی قابل اعتماد به خدمه پرواز در راستای کنترل پارامترهای مهم ریسک ایمنی از جمله، سرعت بلند شدن هواپیما از باند، کنترل سرعت ایمن تیک‌آف و مهم‌تر از همه کنترل از دست رفتن پرواز کمک می‌کند.

واژه‌های کلیدی: ریسک ایمنی پرواز، مدل B.I.M-LSTM، بهینه‌سازی.

۱- مقدمه

امروزه، یکی از مهم‌ترین چالش‌های صنعت هوایی، شرکت‌های هواپیمایی، مسافران هواپیما، رعایت دقیق الزامات ایمنی پرواز جهت کاهش ریسک توسط خدمه پرواز است. (ساموسیر و همکاران، ۲۰۲۲) تیک‌آف، اولین و خطرناک‌ترین مرحله هر پرواز، مستلزم توجه دقیق به شرایط ایمنی خاص به‌خصوص اجرای دقیق الزامات فرایندهای آن در پیکربندی مناسب هواپیما، کنترل موتور، لاستیک، باند، شرایط آب و هوایی است. (گالو آدرو و همکاران، ۲۰۲۱) این حالت پرواز به تنهایی حدود ۴/۷۷ درصد از سوانح مرگبار هوایی در ایران و جهان را به تنهایی به خود اختصاص داده است. (گزارش بوئینگ، آمریکا، ۲۰۲۲) حوادث مرگبار مربوط به ایرلاینز آمریکا (۲۰۰۹)، ایرفرس (۲۰۰۰)، سپاهان (۲۰۱۴)، هواپیمای آموزشی (۱۴۰۱)، اف ۱۴ (۱۴۰۱)، اف ۵ (۱۴۰۰) تنها بخشی از این سوانح است. (گزارش ایکایو، ۲۰۲۲)

در بسیاری از حوادث تیک‌آف، سیستم هواپیما و خدمه نمی‌توانند اطلاعات موتورها، بدنه هواپیما، رادار، ارتباطات، ناوبری و اطلاعات انسانی را به موقع پردازش نمایند. (مایکل ری و همکاران، ۲۰۲۱) سیستم‌های مدیریت ایمنی پرواز (FMS) به دلیل پیچیدگی محاسبات، هنوز ریسک ایمنی پرواز را به صورت دقیق آرایه نمی‌دهد. نتایج بسیاری از مقالات نشان می‌دهد، روش‌های فیزیکی، فازی، آماری و شبکه‌عصبی برای بهینه‌سازی استفاده می‌شود. (لین بی، ۲۰۲۰) اجرای دقیق این روش‌ها به دلیل پیچیدگی محاسبات توأم با خطا و انحرافات در محاسبه و مستلزم صرف زمان زیاد، نمی‌توان درجه ریسک ایمنی پرواز را ارزیابی نمود. (بالاچاندان و همکاران، ۲۰۱۶) به همین خاطر بهبود و توسعه ابزارهای اجرایی ریسک ایمنی پرواز ضروری است.

نتایج مقاله (الکساندرز و همکاران، ۲۰۲۲) نشان داد، ترکیب چندین روش می‌تواند منجر به خروجی بهبود یافته شود. بویژه زمانی که بسیاری از پارامترهای هواپیما در طول پرواز از نوع داده‌های سری زمانی است. (پاش چنکو، ۲۰۱۲) بطور مثال سرعت ۷٪ که ادامه تیک‌آف یا رد احتمالی آن به کنترل آن بستگی دارد اما در برخی از حالت به دلیل چرخش دماغه هواپیما قبل از سرعت مناسب ۷٪ و طول باند ناکافی، کنترل آن دیگر برای توقف ایمن هواپیما موثر نیست. (بالاچاندان و همکاران، ۲۰۱۶)

یادگیری عمیق یک روش قدرتمند برای تحلیل و تفسیر داده‌های پیچیده است که در زمینه‌های مختلف کاربرد دارد. یکی از این زمینه‌ها شناسایی ریسک ایمنی پرواز است که به معنای تشخیص و دسته‌بندی الگوهای حرکت هواپیما در طول پرواز جهت کاهش ریسک احتمالی است. این موضوع برای کاربردهای مختلف مانند ارزیابی عملکرد خدمه پرواز، تشخیص ریسک خطاها و حوادث، بهبود ایمنی و کارایی پرواز و آموزش شبیه‌سازی مفید است. (لی جینک و همکاران، ۲۰۲۳) استفاده از شبکه‌عصبی بازگشتی برای کشف قوانین تغییرات داده موثر است. (پیو وانگ و همکاران، ۲۰۲۳) اما به دلیل حجم انبوه داده‌های پرواز ذخیره شده در جعبه سیاه هواپیما (FDR) جهت بهینه‌سازی نیازمند پلتفرمی مطمئن با ابزارهای کنترلی دقیق برای اکتشاف و آماده‌سازی داده‌ها، انبار داده و مانیتورینگ موثر است. با این وجود به نظر می‌رسد در حال حاضر علیرغم تحقیقات گسترده، چنین الگویی مناسب کارآمد و مشخصی جهت بهبود ریسک ایمنی پرواز و همچنین هماهنگی در استفاده مداوم شرکت‌های هواپیمایی

و فرودگاه‌ها به دلایل ناشناخته‌ای بکار گرفته نشده است. این مقاله در صدد استفاده از مدل BI^۱ که ابزار کنترلی جدید و پیشرفته در اکتشاف و بهره‌برداری از داده‌های عظیم پرواز، پایگاه داده هوشمند و هم‌چنین ابزار مانیتورینگ ویژه‌ای دارد ترکیب با شبکه بازگشتی LSTM، پلتفرم مناسب و کارآمد (B.I.M-LSTM) پیشنهادی جهت بهینه‌سازی ریسک ایمنی پرواز را نخستین بار ارائه دهد.

۲- مبانی نظری پژوهش

بر اساس پیوست ۱۹ ایکایو، هدف اصلی ایمنی پرواز، تجزیه و تحلیل، ارزیابی، کنترل و اقدامات لازم برای کاهش ریسک پرواز است. عامل انسانی رابط انسان و سخت افزار، عامل فنی و شرایط آب و هوایی نقش مهمی در کنترل سوانح هوایی ایفا می‌کنند (ادنان، ۲۰۲۲) مدیریت و ارزیابی پرواز ایمن مستلزم شناسایی ریسک و اطمینان از کاهش آن است. بخش کلیدی این تحلیل، بررسی و اعتبارسنجی رویدادها برای شناسایی اقدامات اصلاحی، شناسایی پیش‌سازهای رویدادها عدم وجود مشکل فنی یا ساختاری و آمادگی هواپیما برای تیک‌آف است. (گایو سان و همکاران، ۲۰۲۰) برای این منظور الگوریتمی برای تشخیص و تجزیه و تحلیل ناهنجاری‌ها و تخلفات در بخش‌های ساختاری و خطاهای کارکنان هواپیمایی که سامانه هوشمندی جهت جمع‌آوری، پردازش و استفاده از داده‌های مربوط به ریسک (انحراف از استانداردها در فعالیت‌های واحدهای مختلف و کارکنان هواپیمایی) توسعه یافته است. معماری مفهومی تضمین کاهش ریسک ایمنی و تقویت ایمنی یکپارچه هواپیما (AIRSAFE) برای جلوگیری از دست رفتن کنترل پرواز، ارزیابی ایمنی، و کنترل انعطاف‌پذیر در موقعیت‌هایی ریسک کمک می‌کند (الکساندرز، ۲۰۲۱)

نتایج مقاله گابریل جری و همکاران (۲۰۲۰) نشان می‌دهد، برآورد پارامترهای داخلی هواپیما همچون نرخ جریان سوخت، تنظیم فلپ‌ها و چرخ فرود با استفاده از ویژگی‌های سامانه نظارت زمینی ایمنی پرواز درصد خطای ریسک ایمنی را کاهش می‌دهد. وانگ پیو و همکاران (۲۰۲۳) یک روش مبتنی بر یادگیری عمیق برای محاسبه بارهای بال هواپیما ارائه داند که روش پیشنهادی به صورت موثر بارهای بال هواپیما را ارزیابی می‌کند. (وانگ پیو و همکاران، ۲۰۲۳)

استفاده از پایه اطلاعاتی گسترده، بازه خطای تحمل‌پذیر را به مقدار زیادی کاهش می‌دهد. این به پارامترهای پرواز آنتروپی وابسته است، که با استفاده از سیستم‌های سایبرنتیک به دست می‌آید که توانایی کنترل انسان - عامل - را به شکل فوری و بیشتر شکل می‌دهد. وجود تبادل نظر ناتحمل‌پذیر نیازمند ارتباط اطلاعاتی مهم بین ماشین (هواپیما) و شخص (عامل آن) است. (کوردل پاول، ۲۰۱۴) سیستم پیشنهادی زامیت مانجین و همکاران^۲ (۲۰۰۸) به طور مداوم پارامترهای عملکرد زمینی با مقایسه عملکرد فعلی از پیش محاسبه‌شده، مشکل هنگام تیک‌آف را شناسایی می‌کرد. سیستمی با توانایی پیش‌بینی مداوم وضعیت تیک‌آف، پتانسیل بهبود ایمنی را دارد. (مانجین و همکاران، ۲۰۰۸)


¹ Business intelligence

² Zammit-Mangion

گویندارجان^۱ و همکاران (۲۰۱۵) یک چارچوب کنترلی بهینه برای تجزیه و تحلیل قوانین کنترل پرواز و تخمین محدودیت‌ها پیشنهاد کرد. روش‌های مبتنی بر هوش مصنوعی، از جمله شبکه‌های عصبی مصنوعی (ANN) سینگ و همکاران (۲۰۱۲) ماشین بردار پشتیبان (SVM) ژو و همکاران (۲۰۱۱) راه جدیدی برای پیش‌بینی مشکلات پروازی در جهت ریسک ایمنی هموار نمود. (ژو و همکاران، ۲۰۱۱)

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. (گرس^۲، ۱۹۹۹) این مدل‌ها می‌توانند چندین لایه از واحدهای محاسباتی پنهان با عملکرد بالا را آموزش دهند. 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. (گابریل و همکاران، ۲۰۲۰) (نگ اریس و همکاران، ۲۰۲۳)

نتایج مقاله بورست (۲۰۱۳) نشان داد، سیستم تقویت ایمنی در راستای جلوگیری از ورود هواپیما به موقعیت خطرناک مثل آب و هوای نامساعد موثر است. بالانچاران و همکاران (۲۰۱۶) با تمرکز کمک به خدمه پرواز در هنگام تیک‌آف پرواز سیستم با استفاده از چارچوب خود کنترلی تطبیقی موقعیتی تصمیم رفتن/نه را ارایه کردند، این سیستم کنترل جهت یا چرخش نامناسب را در نظر نمی‌گرفت. شکل ۱- فرایند تیک‌آف را به صورت گرافیکی و سرعت تیک‌آف V را نشان می‌دهد. (سرعت V برحسب نات در واحد زمانی Sec ارائه شده است.



شکل ۱- فرایند تیک‌آف هواپیما (بالانچاران و همکاران، ۲۰۱۶)

¹ Govindarajan

² Gers

۳- روش پژوهش

مقاله حاضر یک مدل ترکیبی از شبکه عصبی عمیق LSTM و مدل ۵ لایه BI مدلی جدید (B.I.M-LSTM) برای نخستین بار جهت بهینه‌سازی ریسک ایمنی پرواز در مرحله پروازی تیک آف را پیشنهاد می‌دهد. مراحل به این صورت زیر است:

۳-۱- لایه Data Source Layers


تجسم داده برای تفسیر مجموعه داده‌های پیچیده ضروری است و به کاربران امکان می‌دهد، به سرعت و با کارایی بالا از مقدار زیادی اطلاعات استفاده کنند. این روش برای کشف الگوها، روندها و همبستگی است. (سینگه، ۲۰۲۲) ترکیبی از منابع داده با کیفیت بالا و مهندسی ویژگی موثر، می‌تواند بهبود قابل توجهی در نتایج پژوهش یادگیری ماشین داشته باشد و به پیش‌بینی دقیق و معنادار کمک کند. (گیو، ۲۰۱۸) داده‌های پرواز خام از دیتاست استاندارد TCDS (Type /https://www.kaggle.com/datasets https://zenodo.or لینک تا ۲۰۲۰ از لینک Certificate Data Sheet بدست آمد. داده‌ها با استفاده از یک فرآیند چند مرحله‌ای جمع‌آوری و پردازش شد. جدول شماره ۱ ویژگی‌های مهم را نشان می‌دهد.

جدول ۱- ویژگی‌های فرایند ایمنی پرواز در حالت تیک‌آف

منبع	توصیف	ویژگی	ردیف
(بالاچاندان، ۲۰۱۶)	مسافت واقعی مورد نیاز برای شتاب گرفتن، بلند شدن و رسیدن به نقطه ای در ۳۵ فوت بالاتر از باند فرودگاه سرعت تصمیم گیری	سرعت V_1	۱
(بالاچاندان، ۲۰۱۶)	از کار افتادن یکی از موتورهای هواپیما، ادامه تیک آف هواپیما	سرعت ایمن تیک آف V_2	۲
(کوردل پاول، ۲۰۱۴)	استفاده نادرست خلبان و خدمه پرواز از چک لیست	رویه استاندارد	۳
(جان فنگ، ۲۰۲۳)	گشتاور T_{idle} مقدار گشتاوری است که موتور جت زمانی که در حداقل تنظیم قدرت خود قرار دارد تولید می‌کند. بر اساس نیاز هواپیما به برق، هوای فشرده و قدرت هیدرولیک در زمین تنظیم می‌شود.	تنظیم رانش T_{idle}	۴
(گابریل، ۲۰۲۰)	سرعتی که در آن خلبان می‌تواند فلپ‌ها را باز کند.	سرعت کمینه باز فلپ V_{fp}	۵
(بالاچاندان، ۲۰۱۶)	سرعت جدا شدن هواپیما از باند و پرواز و بالارفتن دماغه هواپیما	چرخش: بالاتر از سرعت بلند شدن چرخ جلو VR	۶
(گابریل، ۲۰۲۰)	مشکل لاستیک در هنگام سرعت گرفتن در باند.	خرابی چرخ و لاستیک	۷
(گابریل، ۲۰۲۰)	تنظیم هواپیما برای پرواز تنظیم فلپ‌ها، تنظیم سطح قدرت و بررسی موتور هواپیما، بال‌ها، مخازن سوخت و سایر سیستم برای پرواز ایمن موفق	پیکربندی هواپیما برای تیک‌آف C	۸
(ادرو گالو، ۲۰۲۱)	تعادل بار هواپیما و خطای محاسبه وزن و سوخت	محاسبه وزن	۹


ردیف	ویژگی	توصیف	منبع
۱۰	فشار هوا	فشار هوا یا فشار جو، نیرویی است که در هر نقطه بر حسب وزن ستونی از هوا	(لجینگ لی، ۲۰۲۲)
۱۱	V_{lof}	افزایش سرعت V_{lof} از روش‌های مانند افزایش قدرت موتورها، کاهش وزن هواپیما ...	(جان فنگ، ۲۰۲۳)
۱۲	سیستم هشدار	سیستم هشدار پیکربندی تیک آف (TOCWS) مجهز به یک دستگاه ایمنی است	(ته سین، ۲۰۲۰)
۱۳	مسافت پرواز	مسافتی است که هواپیما با طی آن در فرودگاه مقصد به زمین خواهد نشست.	(یاهدگو، ۲۰۲۳)
۱۴	دما	درجه حرارت هوا	(ادرو گالو، ۲۰۲۱)
۱۵	شرایط آب و هوایی	بارانی، برفی، یخ، صاف، مه آلود	(بورست، ۲۰۱۳)
۱۶	ترافیک هوایی	محاسبه زمانی پرواز برای رسیدن به مقصد	(یی لین، ۲۰۲۰)
۱۷	وزش باد	سرعت وزش باد	(ادرو گالو، ۲۰۲۱)

به طور نمونه ویژگی داده‌های ترافیک هوایی بر حسب ماه شکل (۲) و ویژگی مربوط به نمودار متغییر هدف ارزیابی ریسک ایمنی پرواز شکل (۳) نشان داده شده است.




شکل ۲- نمودار ترافیک هوایی در داده‌های پرواز
شکل ۳- نمودار متغییر هدف برای ارزیابی ایمنی پرواز

هم چنین شکل ۴- ویژگی داده‌های شرایط آب و هوایی شامل برفی، بارانی، مه آلود، صاف و ... را نمایش می‌دهد. و شکل ۵- ویژگی داده متغییر سرعت باد را نشان می‌دهد:



شکل ۵- سرعت وزش باد



شکل ۴- شرایط آب و هوایی، برفی، بارانی، مه آلود

۳-۲- لایه ETL

این لایه بر اساس معماری BI شامل سه مرحله مهم در فرایند آماده‌سازی داده است. فرآیند پیش‌پردازش داده‌ها شامل پاکسازی داده‌ها، تبدیل داده‌ها، نرمال‌سازی و استانداردسازی داده‌ها است. در مرحله اول، ۱۷ ویژگی مربوط به داده‌های تیک‌آف به عنوان ورودی به شبکه LSTM استفاده می‌شود 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:

$$x = \begin{bmatrix} p_{t-n}^1 & p_{t-n+1}^1 & \dots & p_{t-1}^1 & p_t^1 \\ p_{t-n}^2 & p_{t-n+1}^2 & \dots & p_{t-1}^2 & p_t^2 \\ p_{t-n}^3 & p_{t-n+1}^3 & \dots & p_{t-1}^3 & p_t^3 \\ \vdots & \vdots & \dots & \vdots & \vdots \\ p_{t-n}^{17} & p_{t-n+1}^{17} & \dots & p_{t-1}^{17} & p_t^{17} \end{bmatrix}$$

در این ماتریس، درایه p_{t-n}^{17} نشان دهنده مقدار پارامتر پرواز (سرعت وزش باد) در (t-n) timestep 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.

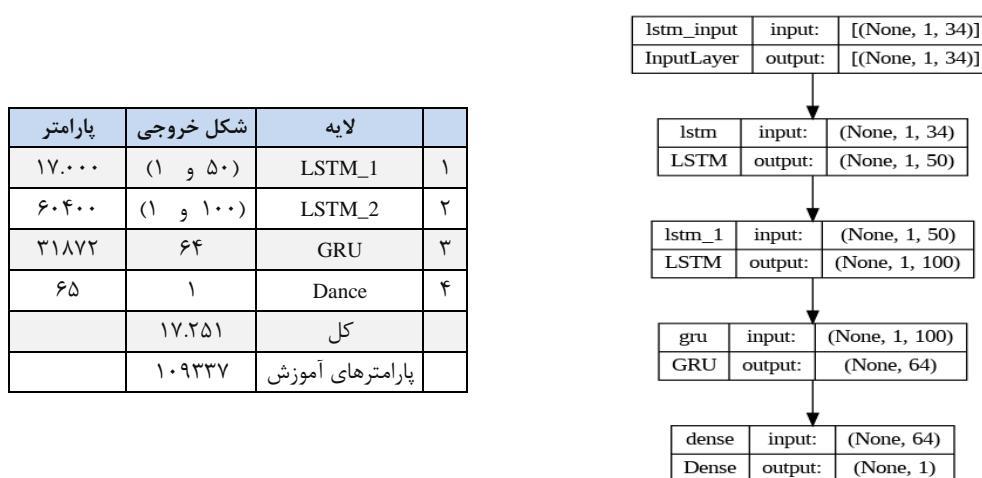
هدف از پاکسازی داده‌ها حذف داده‌های غیرطبیعی جهت به دست آوردن اطلاعات اندازه‌گیری و ویژگی مرتبط دقیق داده‌هاست. آماده‌سازی داده‌ها برای الگوریتم‌های یادگیری ماشین، به دو روش تبدیل داده استفاده شد: رمزگذاری داده و نرمال‌سازی داده. در رمزگذاری داده، ویژگی‌های طبقه‌ای به نمایش عددی تبدیل شدند و در نرمال‌سازی 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 گرادینان و بهینه‌سازی پارامترها مورد استفاده قرار گرفت و تعداد ۸۶۴۴ یعنی ۳۰ درصد از داده‌ها به داده‌های آزمایشی مدل به طور تصادفی اختصاص یافت.

۳-۳ - معماری لایه LSTM

شبکه‌های عصبی بازگشتی (RNN) به دلیل قابلیت مدل‌سازی داده‌های توالی در زمینه یادگیری ماشین توسعه یافت. (زوها، ۲۰۲۱) در این شبکه، اطلاعات از طریق یک زنجیره از گره‌های متصل، با پردازش داده‌های توالی ورودی در جهت تکامل توالی منتقل می‌شود. (زوا، ۲۰۱۹) از بین مدل‌های یادگیری مختلف، مدل یادگیری عمیق (LSTM) به علت اینکه هر یک از داده‌های پرواز وابسته به ورودی‌های ماقبل خود هستند و نیاز به نوعی حافظه دارند. شبکه‌های LSTM برای بهینه‌سازی انتخاب شد. شبکه عصبی LSTM از چندین گیت و متغیر تشکیل شده است. در این مقاله جهت بهینه‌سازی از ۲ لایه LSTM با ترتیب با ۵۰ نورون، ۱۰۰ نورون و یک لایه GRU با ۱۰۰ نورون و یک لایه خروجی با ۶۴ نورون استفاده شد مجموعه آموزش و مجموعه آزمون جهت بهینه‌سازی استفاده نمایند. معماری آن در شکل ۶- نشان داده شده است:



شکل ۶- معماری شبکه LSTM چند لایه

نورون‌های LSTM توسط گیت فراموشی f_t ، تعیین می‌کند چه مقدار اطلاعات از حالت سلول قبلی باید حفظ شود به صورت زیر محاسبه می‌شود:

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

در اینجا، w_i 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. که به صورت زیر محاسبه می‌شود:

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

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

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (5)$$

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 که به صورت زیر محاسبه می‌شود:

$$O_t = \sigma(w_o \times [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = O_t \times \tanh(C_t) \quad (7)$$

در اینجا، w_o ماتریس وزن دروازه خروجی و b_o 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 نرمال‌سازی 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.

۳-۴- معیارهای عملکرد مدل

قابلیت پیش‌بینی و عملکرد توسعه داده شده با استفاده از روشهای ریاضی و آماری مشخص شد به منظور بررسی عملکرد شبکه، از میانگین مربعات خطا (MSE) به‌عنوان معیاری برای سنجش دقت نتایج مدل پیشنهادی استفاده شد.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \bar{y})^2 \quad (8)$$

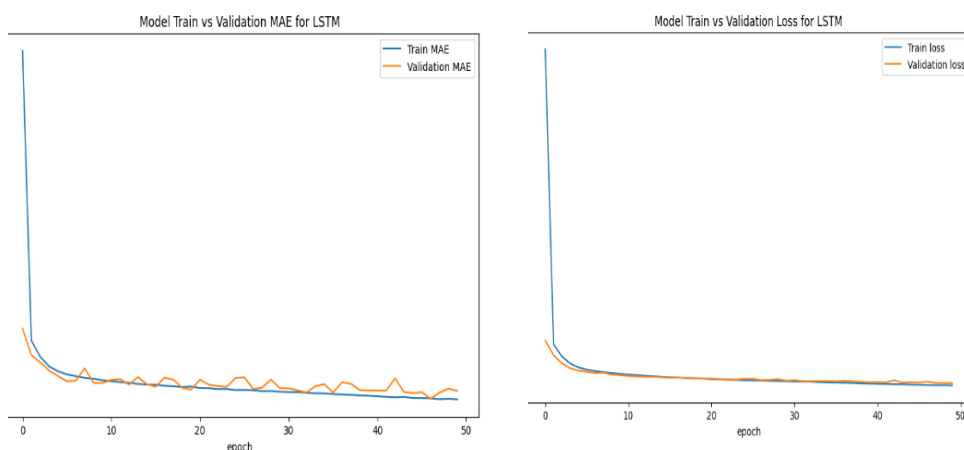
در روابط فوق n نشان دهنده تعداد مشاهدات، مقادیر اندازه‌گیری شده و y نشان‌دهنده مقدار پیش‌بینی شده است. قابلیت پیش‌بینی سیستم توسعه داده شده توسط درصد میانگین مطلق خطای سیستم (MAPE) که نشان دهنده انحراف بین مقادیر تجربی و پیش‌بینی شده است به صورت رابطه زیر محاسبه شد.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{y - \bar{y}}{y} \quad (9)$$

در رابطه فوق نیز n نشان‌دهنده تعداد مشاهدات، y مقادیر اندازه‌گیری شده و نشان‌دهنده مقدار پیش‌بینی شده است. خطای نسبی انحراف بین مقادیر پیش‌بینی شده و داده‌های اندازه‌گیری شده را نشان می‌دهد و بهتر است که مقدار آن به صفر میل کند. آموزش مدل LSTM این معنی است پارامترهای آزاد شبکه (وزن‌ها و بایاس‌ها) توسط الگوریتم‌های آموزش و بر اساس داده‌های آموزشی (شامل بردارهای ورودی و هدف) به گونه‌ای بهینه شوند که مقدار خطای بین خروجی شبکه و پارامتر هدف به حداقل مقدار ممکن خود برسد.

۴- یافته‌ها

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.



شکل ۸- نمودار خطای میانگین مربعات

شکل ۷- نمودار خطای میانگین مطلق

نمودار MAE یا خطای میانگین مطلق یک شاخص برای اندازه‌گیری میزان خطای یک تخمین‌گر نسبت به مقدار واقعی است. این شاخص برابر با میانگین مقادیر مطلق اختلاف بین تخمین‌گر و مقدار واقعی است. چون مقدار این شاخص کمتر است، نشان‌دهنده دقت بیشتر تخمین‌گر است. و خطای آن برابر $0/261$ است. همانطور که در نمودار شماره ۷ 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 ۷ و ۸ دارای دو خط است که بردارهای ورودی و هدف بصورت تصادفی به دو مجموعه آموزشی (70%)، و آزمایشی (30%) تقسیم شده است. مجموعه ارزیابی در راستای حفظ عمومیت 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 MSE بدست آمده مدل را نشان می‌دهد کمترین مقدار به دست آمده از رابطه ۵ برای میانگین مربعات خطا برابر با ۰/۱۱۶ و در اپوک ۵۰ نقطه بهینه مدل است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \bar{y})^2 \quad (10)$$

با بررسی این نمودار نتایج حاصل به دلیل زیر مطلوب می‌باشد، مقدار خطایی میانگین مربعات نهایی کوچک است. خطای مجموعه آزمایشی با خطای مجموعه ارزیابی دارای رفتار و خصوصیات مشابهی هستند. تا تکرار ۵۰ بهترین کارایی در مورد مجموعه به وقوع می‌پیوندد هیچ بیش برآزشی رخ نداده است. جایی که (نقطه بهینه) بهترین عملکرد اعتبار سنجی رخ می‌دهد.

جدول ۴- میزان خطای یادگیری (MSE)

تست	آموزش	
۶.۵۹٪	۶.۴۲٪	خطای یادگیری
۶.۳۸۴	۶/۳۴۴	RMSE
	۰/۱۱۶	MSE
	۰/۲۶۱	MAD
۸۶۴۴	۲۰۱۶۹	کل داده پرواز (۲۸۸۱۳)

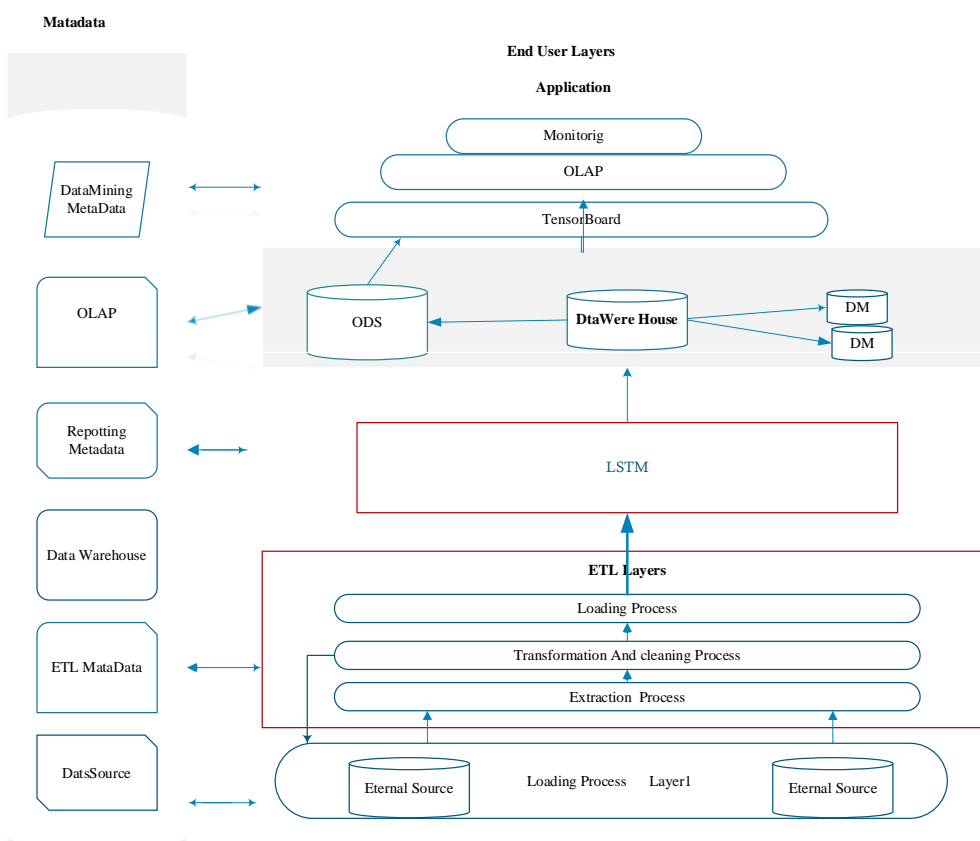
جدول ۴- میزان خطای یادگیری (MSE) در هر یک از گروه داده‌های آموزشی، آزمایشی را نشان می‌دهد، بر این اساس چون مقادیر این شاخص به عدد صفر نزدیکتر است، نشان دهنده میزان کمتر خطا گروه داده است و درصد اطمینان مدل قابل قبول است.

۴-۱- مدل پیشنهادی B.I.M-LSTM

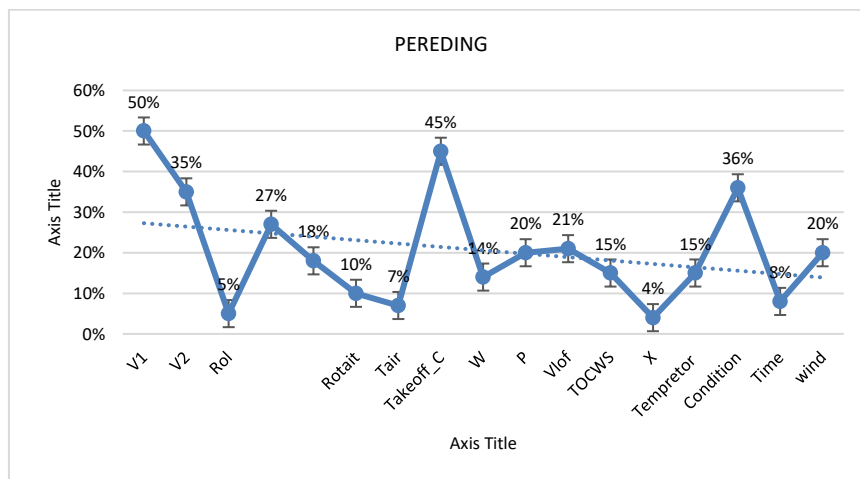
شکل ۸- ساختار مدل بهینه سازی B.I.M-LSTM که برای ایمنی هواپیما در حالت تیک آف مورد استفاده قرار می‌گیرد نشان می‌دهد:

به طوری که شکل ۸- 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 اطلاعات (OLAP) را در فرمت‌های مختلف به خدمه پرواز و کادر فرودگاهی به‌صورت سریع و دقیق نشان می‌دهد. شکل ۹- عوامل ایمنی پرواز را نشان می‌دهد که مهمترین عامل در ارزیابی ایمنی با ۵۰ درصد سرعت تیک‌آف یا همان VI است. و عامل بعدی پیکربندی هواپیما ۴۵ درصد را به خود اختصاص می‌دهد. سایر عوامل ریسک با درصد احتمال وقوع در نمودار نشان داده شده است.



شکل شماره ۸- مدل پیشنهادی B.I.M-LSTM بهینه‌سازی تیک‌آف



شکل ۹- پیش‌بینی عوامل ریسک ایمنی پرواز (تیک‌آف)

۵- نتایج و بحث

مقاله حاضر مدل بهینه‌سازی ریسک ایمنی پرواز تیک‌آف با استفاده از ترکیب BI و RNN-LSTM (B.I.M-LSTM) را ارائه می‌دهد. مدل پیشنهادی به دلیل برخورداری از ابزارهای پشرفته بهینه‌سازی از جمله لایه ETL مشکل استخراج، اکتشاف، دسته‌بندی انبوه داده‌ای پرواز را حل می‌کند. بر اساس تحقیقات کوین شریدن (۲۰۲۰) چالش نیاز به افزایش مستمر شناسایی ریسک برای بهبود تحلیل ایمنی پرواز وجود داشت، لایه متا دیتا مدل زمینه قابلیت ذخیره‌سازی و پردازش داده‌ها، در تجزیه و تحلیل ایمنی پرواز را ممکن می‌سازد. به‌طور پیوسته در صورت تغییر اطلاعات، آن را بروزرسانی کرده و به صورت لحظه‌ای نشان می‌دهد. و از شبکه عصبی LSTM در تخمین پارامترهای متناسب با سیستم نظارت و ایمنی پرواز استفاده می‌کند. از جمله سرعت هواپیما در لحظه بلند شدن از باند، سرعت ایمن هواپیما تا رسیدن به ارتفاع ۳۵ فوتی زمین. همبستگی بالای منحنی‌های تخمین با منحنی‌های واقعی بیانگر این است که خطا به نظر غیرقابل توجه است و ریسک ایمنی پرواز با خطای ۶ درصد بهتر از مدل FSM که در موارد اضطراری سیستمی بسیار ناکارآمد است (بلانچاندران، ۲۰۱۵) (یو ها و جی، ۲۰۲۲)، ارزیابی می‌شود این در حالی است روش پیشنهادی پیو وانگ (۲۰۲۳) به صورت موثر دارای خطای نسبی متوسط ۸ درصد است. پس این مدل نسبت به سایر مدل‌های عمقی عملکرد بهتری نشان می‌دهد. الگوی پیشنهادی با راهبردی کارآمد و قابل اعتماد به فرودگاه‌ها، شرکت‌های هواپیمایی و همچنین مسافران کمک خواهند کرد ریسک ایمنی تیک‌آف را با دقت بالا پیش‌بینی شود که نشان دهنده بهبود مدل پیش‌بینی است. این الگو با راهبردی قابل اعتماد به خدمه پرواز در ایستگاه زمینی و هوایی در راستای کنترل پارامترهای مهم ریسک ایمنی پرواز از جمله، سرعت بلند شدن هواپیما از باند، کنترل سرعت ایمن تیک‌آف، کنترل فلپ‌ها و مهم‌تر از همه کنترل از دست رفتن پرواز کمک می‌کند. با این وجود مدل پیشنهادی (B.I.M-LSTM) نیاز به بررسی بیشتر در تحقیقات آینده دارد.

فهرست منابع

- * Aleksandrs Bitiņš, Ruta Bogdane, Vladimir Shestakov, Anastasija Stepanova (2022) the ORETICAL AND METHODOLOGICAL APPROACHES TO THE INFORMATION BASE FOR AN AIRLINE'S FLIGHT SAFETY SYSTEM Transactions on Aerospace Research eISSN 2545-2835, VOL. 266, NO. 1/2022, 75-83 DOI: 10.2478/tar-2022-0006
- * Balachandran. S and Ella. M. Atkins (2015) Flight Safety Assessment and anagement for Takeoff Using Deterministic Moore Machines JOURNAL OFAEROSPACE INFORMATION SYSTEMS Vol. 12, No. 9, September
- * 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.
- * Borst, C., Grootendorst, F. H., Brouwer, D. I. K., Bedoya, C., Mulder, M., and van Paassen, M. M., "Design and Evaluation of a Safety Augmentation System for Aircraft," *Journal of Aircraft*, Vol. 51, No. 1, 2013, pp. 12–22. doi:10.2514/1.C031500
- * D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- * EDAN HABLER, RON BITTON, and ASAF SHABTAI(2021) Evaluating the Security of Aircraft Systems arXiv:2209.04028v1 [cs.CR] 8 Sep 2022
- * 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," 1999.
- * 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. pp.ISBN: 978-1-7281-5381-0
- * Govindarajan, N., De Visser, C., Van Kampen, E., Krishnakumar, K., Barlow, J., and Stepanyan, V., "Optimal Control Framework for Estimating Autopilot Safety Margins," *Journal of Guidance, Control, and Dynamics*, Vol. 38, No. 7, 2015, pp. 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. <https://doi.org/10.1371/journal.pone.0231391>
- * He, Z.; Zhou, J.; Dai, H.N.; Wang, H. Gold Price Forecast Based on LSTM-CNN Model. In Proceedings of the 2019 IEEE Intl Conference on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress (DASC/PiCom/CBDCCom/ CyberSciTech), Fukuoka, Japan, 5–8 August 2019; pp. 1046–1053.
- * ICAO, *Doc 9859, Safety management manual*, 4th ed. Montréal, Quebec, Canada: International Civil Aviation Organization (ICAO), 2022.
- * 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. DOI: 10.3934/era.2023005
- * Johar Samosir, Sarinah Sihombing, Hendro Kuntohadi () Effect of Effectiveness of Use of Electronic Flight Bags on Flight Safety at PT. Garuda Indonesia Annals of R.S.C.B., ISSN:1583-6258, Vol. 25, Issue 3, 2021, Pages. 112 - 122 Received 16 February 2021; Accepted 08 March 2021.
- * JuanFang, QiangangZheng, ChangpengCai, HaoyinChen, HaiboZhang (2023) Deep reinforcement learning method for turbofan engine acceleration optimization problem within full flight envelope Aerospace Science and Technology [m5G; v1.333] P.1 (1-14)
- * Mickael Rey, Daniel Aloise , François Soumis ,Romanic Pieugueu (2021)

- * 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, 2023
- * PeiyaoWang, Mingxin Yu1 , Guang Yan1, Jiabin Xia, Jiawei Liu 1 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-permissionsDOI: 177/00202940221145971journals.sagepub.com/home/mac
- * Singh, G.; Singh, J.; Prabha, C. Data visualization and its key fundamentals: A comprehensive survey. In Proceedings of the 20227th International Conference on Communication and Electronics Systems (ICES), Coimbatore, India, 22–24 June 2022.
- * T. Hastie, R. Tibshirani, J. Friedman, and J. Franklin, “The elements of statistical learning: data mining, inference and prediction,” *The Mathematical Intelligencer*, vol. 27, no. 2, pp. 83–85, 2005
- * Tahsin Sejat Saniat, Tahiat Goni, Shaikat M. Galib (2020) LSTM RECURRENT NEURAL NETWORK ASSISTED AIRCRAFT STALL PREDICTION FOR ENHANCED SITUATIONAL AWARENESS arXiv:2012.04876v1 [cs.LG] 9 Dec 2020
- * Yi Lin , Linjie Deng, Zhengmao Chen, Xiping Wu, Jianwei Zhang, and Bo Yang(2020) A Real-Time ATC Safety Monitoring nramework Using a Deep Learning Approach IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS, VOL. 21, NO. 11, NOVEMBER 2020
- * Zammit-Mangion, D., and Eshelby, M., “Simplified Algorithm to Model Aircraft Acceleration During Takeoff,” *Journal of Aircraft*, Vol. 45, No. 4, 2008, pp. 1090–1097. doi:10.2514/1.22966
- * Zhu, D.; Wang, Y.; Zhang, F. Energy Price Prediction Integrated with Singular Spectrum Analysis and Long Short-Term Memory Network against the Background of Carbon Neutrality. *Energies* 2022, 15, 8128. [CrossRef]

Design an intelligent model to optimize the safety risk of the takeoff flight using B.I.M-LSTM

Mansour Yahyavi

Ph.D .Student, Department of Information Technology Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran
yahyavi@shariaty.ac.ir

Abbas Toloie -Eshlaghi

Corresponding Author: Professor, Department of Information Technology Management, Science and Research Branch, Islamic Azad University, Tehran, Iran.
Toloie@gmail.com

Mohammad Ali Afshar Kazemi

professor ,Department Information Technology Management, Central Tehran Branch, Islamic Azad University, Tehran
dr.mafshar@gmail.com

Reza Radfar

professor, Department of Information Technology Management, Science and Research Branch, Islamic Azad University, Tehran, Iran,
radfar@gmail.com

Abstract

This paper presents a new model for optimizing the safety risk of take-off, as the most important and dangerous flight process, using a combination of BI algorithm and recurrent neural network LSTM. The goal is to train an effective neural network with past data records of air accidents to predict safety risk parameters. For this purpose, 17 safety features, such as weather conditions, aircraft configuration and preparation, flight information and air traffic were obtained. The data related to 2019 to 2020 was selected after performing exploration, summarization, cleaning, normalization operations with 28813 data records. Due to the dependence of flight data on their previous inputs and the need for a kind of memory, training was performed by deep learning algorithm (LSTM) in Python. After learning, the learning error was about 6 percent and the mean square error was about 116/0. It shows that the error percentage is negligible and the proposed model has high validity. Also, this model solved the problem of exploration and cleaning of bulk flight data by using advanced tools such as ETL, metadata and real-time monitoring and was able to predict the most important safety risk factor (speed V1) with high accuracy. This model helps the flight crew to control important risk parameters such as aircraft lift-off speed, safe take-off speed and most importantly flight loss control with a reliable strategy.

Keywords: Flight safety risk, B.I.M-LSTM model, optimization