

تحلیل آماری و پیش‌بینی شدت سوانح هوایی با استفاده از الگوریتم‌های یادگیری ماشین: مطالعه‌ای بر داده‌های سوانح آمریکا در پایگاه داده ICAO

تاریخ دریافت: ۱۴۰۴/۰۸/۱۶

تاریخ پذیرش: ۱۴۰۵/۰۲/۲۷

پرهام حسن^۱، حمیدرضا ضرغامی^۲

۱ کارشناسی ارشد آمار ریاضی، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشگاه تهران، ایران، parham.hassan@ut.ac.ir

۲ دانشیار مهندسی صنایع، دانشکده تحصیلات تکمیلی، دانشگاه علوم و فنون هوایی شهید ستاری، تهران، ایران

چکیده

ایمنی پرواز و کاهش سوانح هوایی همواره از مهم‌ترین دغدغه‌های صنعت هوانوردی و نهادهای مرتبط به شمار می‌رود. این پژوهش با هدف تحلیل آمار توصیفی، استنباطی و پیش‌بینی شدت سوانح هوایی با استفاده از مدل‌های یادگیری ماشین انجام شده است. داده‌های پژوهش شامل سوانح هوایی با متغیرهایی چون مرحله پرواز، نوع موتور، نوع ریسک، نوع وسیله پرنده و تعداد موتورها است. در مرحله نخست، تحلیل‌های توصیفی و استنباطی نشان دادند که بین شدت سانحه و عواملی فنی و محیطی رابطه معناداری وجود دارد. سپس، برای پیش‌بینی سوانح منجر به مرگ و میر از مدل‌های رگرسیون لجستیک، درخت تصمیم، جنگل تصادفی و درخت تقویت یافته شدید استفاده شده است. نتایج ارزیابی عملکرد نشان داد مدل XGBoost با دقت ۰.۸۷۶ و حساسیت ۰.۶۷۶ بهترین نتایج را ارائه کرده است. این یافته بیانگر برتری مدل‌های یادگیری ماشین نسبت به مدل‌های آماری سنتی در تحلیل الگوهای پیچیده سوانح هوایی است. نتایج این پژوهش می‌تواند مبنایی برای ارتقای ایمنی پرواز و کاهش ریسک سوانح در سازمان‌های هوانوردی باشد.

واژه‌های کلیدی: سوانح هوایی، تحلیل آماری، یادگیری ماشین، ایمنی پرواز

Statistical analysis and prediction of aviation accident severity using machine learning algorithms: A study of US accident data in ICAO database

Parham Hassan¹, Hamid Reza Zarghami²

1- M.Sc. in Mathematical Statistics, Faculty of Mathematics, Statistics and Computer Science, University of Tehran, Iran.

2- Associate Professor of Industrial Engineering, Faculty of Graduate Studies, Shahid Sattari University of Aerospace Science and Technology, Tehran, Iran

Abstract

Flight safety and reducing air accidents have always been the most important concerns of the aviation industry and related institutions. This study aimed to analyze descriptive and inferential statistics and predict the severity of air accidents using machine learning models. The research data included air accidents with variables such as flight phase, engine type, risk type, aircraft type, and number of engines. In the first stage, descriptive and inferential analyses showed that there is a significant relationship between the severity of the accident and technical and environmental factors. Then, logistic regression, decision tree, random forest, and extreme gradient boosted tree models were used to predict fatal accidents. The performance evaluation results showed that the XGBoost model provided the best results with an accuracy of 0.876 and a sensitivity of 0.676. This finding indicates the superiority of machine learning models over traditional statistical models in analyzing complex patterns of air accidents. The results of this research can be a basis for improving flight safety and reducing the risk of accidents in aviation organizations.

Keywords: Aviation Accidents, Statistical Analysis, Machine Learning, Flight Safety

۱۴۳

سال ۱۴- شماره ۲

پاییز و زمستان ۱۴۰۴

نشریه علمی



تحلیل آماری و پیش‌بینی شدت سوانح هوایی با استفاده از الگوریتم‌های یادگیری ماشین: مطالعه‌ای بر داده‌های سوانح آمریکا در پایگاه داده ICAO

۱. مقدمه

ایمینی در حمل و نقل هوایی یکی از مهم ترین شاخص های توسعه پایدار و امنیت عمومی در جوامع مدرن است. هر سانحه هوایی، علاوه بر تلفات انسانی و خسارات مالی گسترده، می تواند اثرات بلندمدت بر اعتماد عمومی، عملکرد خطوط هوایی و سیاست گذاری های ایمینی داشته باشد. بنابراین، شناسایی عوامل مؤثر بر وقوع و شدت سوانح هوایی، تحلیل دقیق داده ها و پیش بینی سوانح پرریسک، از اولویتهای اصلی پژوهشگران و سازمان های نظارتی است.

با گسترش حجم داده های مربوط به سوانح هوایی و پیچیدگی روابط میان عوامل انسانی، فنی و محیطی، روش های سنتی تحلیل داده دیگر پاسخگوی نیازهای علمی و عملی نیستند. در این راستا، علم داده^۱ و یادگیری ماشین^۲ به عنوان ابزارهایی حیاتی برای تحلیل داده های حجیم و پیچیده مطرح شده اند. این رویکردها امکان شناسایی الگوهای پنهان، مدل سازی روابط غیرخطی و ارائه پیش بینی های قابل اعتماد را فراهم می کنند.

سازمان بین المللی هوانوردی غیرنظامی (ICAO) به عنوان یک نهاد تخصصی وابسته به سازمان ملل متحد، مسئول توسعه استانداردها و رویه های بین المللی در حوزه ایمینی، کارایی و پایداری حمل و نقل هوایی است. این سازمان با گردآوری، استانداردسازی و انتشار داده های مربوط به سوانح و حوادث هوایی در سطح جهانی، نقش

کلیدی در پایش ایمینی و بهبود سیاست های نظارتی دارد. پایگاه داده سوانح ICAO یکی از مهمترین منابع اطلاعاتی در این حوزه به شمار می رود که شامل جزئیات مرتبط با نوع رخداد، مرحله پرواز، نوع موتور و پیامدهای سانحه است. داده های مورد استفاده در این پژوهش از پایگاه داده ICAO استخراج شده اند تا تحلیلی مبتنی بر داده های واقعی و استاندارد جهانی ارائه شود.

استفاده از تحلیل آماری توصیفی شامل فراوانی ها، نمودارها و جداول آماری، تصویر واضحی از داده ها و روندهای کلی ارائه می کند. از سوی دیگر، تحلیل آماری استنباطی با استفاده از آزمون فرض ها و مدل های رگرسیونی، امکان استخراج روابط معنادار میان عوامل و پیامدهای سانحه را فراهم می آورد. این دو لایه تحلیل، زمانی که با الگوریتم های یادگیری ماشین مانند درخت تصمیم، جنگل تصادفی و درخت تقویت یافته شدید ترکیب شوند، چارچوبی قوی برای شناسایی عوامل کلیدی و پیش بینی شدت سانحه ایجاد می کنند و می توانند در طراحی سامانه های هشدار سریع و سیاست گذاری های ایمینی کاربرد داشته باشند.

هدف این پژوهش، ارائه یک چارچوب تحلیلی تلفیقی برای داده های سوانح هوایی ثبت شده در پایگاه ICAO برای کشور آمریکا در بازه زمانی ۲۰۰۸ تا ۲۰۲۲ است. چارچوب این پژوهش شامل مراحل زیر است:

- تحلیل آماری توصیفی برای بررسی توزیع داده ها، روندها، الگوها و شناسایی ویژگی های کلیدی

۱۴۴-

سال ۱۴- شماره ۲

پاییز و زمستان ۱۴۰۴

نشریه علمی



- تحلیل آماری استنباطی برای آزمون روابط میان شدت سانحه و عوامل فنی و محیطی
 - بکارگیری الگوریتم‌های یادگیری ماشین برای مدل‌سازی و پیش‌بینی شدت سوانح هوایی
- این پژوهش با ارائه تحلیلی چندلایه، امکان طراحی سیاست‌های پیشگیرانه، آموزش‌های هدفمند و توسعه سامانه‌های هشدار سریع را برای سازمان‌های نظارتی فراهم می‌آورد و نمونه‌ای بارز از کاربرد علم داده و یادگیری ماشین در حوزه ایمنی هوانوردی محسوب می‌شود.

۲. پیشینه پژوهش

مطالعه سوانح هوایی از دیرباز به عنوان یکی از حوزه‌های کلیدی در ارتقای ایمنی پرواز مورد توجه پژوهشگران و سازمان‌های بین‌المللی بوده است. با افزایش حجم داده‌های سوانح هوایی و پیچیدگی روابط میان عوامل انسانی، فنی و محیطی و همچنین ظهور علم داده و یادگیری ماشین؛ واضح است که روش‌های سنتی تحلیل داده، به‌تنهایی برای کشف الگوهای پنهان و ارائه پیش‌بینی‌های کاربردی کافی نیستند. هم‌زمان، دو جریان پژوهشی مهم در ادبیات پژوهش ایمنی هوانوردی شکل گرفت: یکی یادگیری ماشین برای مدل‌سازی و پیش‌بینی شدت یا وقوع سوانح و دیگری متن‌کاوی^۴ و پردازش زبان طبیعی (NLP)^۵ برای استخراج دانش از گزارش‌های سوانح و متون غیرساختاری است.

در حوزه یادگیری ماشین، مطالعات متعددی اثبات کرده‌اند که الگوریتم‌هایی مانند درخت تصمیم (DT)^۶، جنگل تصادفی (RF)^۷، ماشین بردار

پشتیبان (SVM)^۸، شبکه‌های عصبی (NN)^۹ و روش‌های ترکیبی^{۱۰}، قادر به مدل‌سازی روابط پیچیده میان عوامل حادثه و پیش‌بینی شدت سانحه هستند [۵-۱]. برای مثال، پژوهشی که داده‌های ۱,۲۹۷ سانحه فرود هواپیما در ایالات متحده را تحلیل کرده بود، نشان داده است که مدل SVM با کرنل RBF^{۱۱} توانسته تا دقت حداکثری (۹۶٪) برای پیش‌بینی خسارت هواپیما و ۹۸٪ برای پیش‌بینی جراحات فردی را بدست آورد؛ این مطالعه اهمیت عواملی چون ساعات پرواز خلبان، سن خلبان، مؤلفه باد عرضی، شماره باند فرود و وجود موانع را برجسته کرده است [۶]. پژوهش دیگری با بررسی سوانح هوایی ۳ کشور (ایالات متحده، کانادا و استرالیا) بر مجموعه داده‌های سوانح از ۳ پایگاه داده مختلف، نشان داد بهترین دقت (حدود ۸۱٪) توسط SVM حاصل شده است. همچنین این پژوهش به چالش‌های کیفیت داده‌ها، تفاوت ساختار داده‌های ملی و انتقال‌پذیری مدل‌ها نیز اشاره کرده است [۷]. مطالعه‌ای دیگر با بکارگیری مدل جنگل تصادفی بر گزارشات وقوع ICAO نشان داد که این مدل بیش از ۴۵ هزار گزارش را با دقت تقریبی بین ۸۰ تا ۹۳ درصد دسته‌بندی می‌کند [۸].

پژوهش‌های جدیدتر همچنین به کاربرد شبکه‌های عصبی عمیق، CNN^{۱۲} و LSTM^{۱۳} در دسته‌بندی شدت سانحه پرداخته‌اند. مطالعه‌ای با تحلیل بیش از ۵۳,۰۰۰ گزارش حادثه در استرالیا نشان داد که مدل‌های یادگیری عمیق دقت بالایی در طبقه‌بندی سطح آسیب دارند و می‌توانند الگوهای پیچیده را شناسایی کنند [۹].





همچنین پژوهش‌های جدید نشان داده‌اند که مدل‌های یادگیری ترکیبی نسبت به مدل‌های منفرد عملکرد بهتری در پیش‌بینی شدت و ریسک سانحه دارند [۱۰-۱۳] و مدل XGboost نیز در تحلیل و پیش‌بینی شدت سوانح جاده‌ای نیز مورد توجه پژوهشگران قرار گرفته است [۱۴-۱۶].

تحول دیگر در این زمینه، استفاده از تکنیک‌های متن‌کاوی و پردازش زبان طبیعی است. بسیاری از داده‌های سوانح هوایی به شکل متون آزاد، گزارش‌های سانحه و شرح ماجرا که معمولاً ساختاریافته نیستند، ثبت می‌شوند؛ تحلیل چنین داده‌هایی با روش‌های عددی معمول دشوار است. بنابراین، پژوهشگران روش‌های متن‌کاوی برای استخراج موضوعات پنهان، خوشه‌بندی علل، تحلیل هم‌رخدادی کلمات و ارتباط عوامل بکار گرفته‌اند. به عنوان مثال پژوهشی کاربرد متن‌کاوی را در شناسایی موضوعات پنهان و ساختارهای ارتباطی میان عوامل ریسک نشان داده است. این پژوهش با ترکیب مدل‌های تشخیص موضوع و تحلیل شبکه‌ای، موفق شد تا ارتباط میان کلمات کلیدی برای مشخص کردن عوامل موثر را در گزارش‌های سانحه هوایی استخراج کنند؛ روابطی که در تحلیل‌های سنتی عددی به راحتی قابل تشخیص نبودند [۱۷]. مطالعه‌ای دیگر با استفاده از روش‌های نیمه‌نظارتی واژگان کلیدی و مدل‌سازی موضوع، توانسته تا موضوعات مهم و پنهان گزارش‌ها را شناسایی کند و داده‌ها را برای استفاده در الگوریتم‌های یادگیری ماشین آماده کند [۱۸].

در ایران نیز پژوهش در حوزه تحلیل سوانح هوایی مورد توجه پژوهشگران قرار گرفته است. به عنوان مثال، پژوهشی [۱۹] با تحلیل ۴۶ حادثه و سانحه وخیم هوانوردی غیرنظامی ایران در سال‌های ۱۳۵۸ تا ۱۴۰۰ نشان داده است که عامل انسانی و خطاهای خلبانان با

سن و تجربه کمتر، بیشترین نقش را در بروز این حوادث دارند و خرابی در ارباب فرود و موتور از مهم‌ترین حالات خطا محسوب می‌شوند. مطالعه‌ای دیگر [۲۰] با استفاده از ابزارهای داده‌کاوی به تحلیل سوانح پروازی هوانیروز در بازه ۱۳۶۸ تا ۱۳۹۸ پرداخته است. نتایج این پژوهش نشان می‌دهد که در حدود نیمی از وقایع، هیچگونه آسیبی به وسیله پرنده وارد نشده و خلبانان دارای ۱۵ تا ۲۰ سال تجربه پروازی ریسک بالاتری نسبت به سایر خلبانان دارند. پژوهشی جدیدتر [۲۱] به تحلیل سوانح هوایی مرتبط با پدیده‌های جوی و شرایط آب و هوایی پرداخته است و به تأثیر قابل توجه خطرات هواشناسی بر ایمنی پرواز در ایران تأکید کرده است.

به طور کلی، مرور پیشینه پژوهش‌ها نشان می‌دهد که استفاده از روش‌های داده‌محور، رویکردی اثربخش برای تحلیل سوانح هوایی و پیش‌بینی شدت آن‌ها است. این رویکرد نه تنها امکان شناسایی عوامل انسانی، فنی و محیطی را بهبود می‌بخشد، بلکه مسیر توسعه سامانه‌های هوشمند هشدار و پیشگیری از سوانح را نیز هموار می‌سازد.

۳. روش‌شناسی پژوهش

۳-۱. داده‌ها و پیش‌پردازش

این پژوهش بر روی داده‌های سوانح هوایی ایالات متحده در بازه زمانی ۲۰۰۸ تا ۲۰۲۲ متمرکز است. داده‌ها از پایگاه داده عمومی ICAO استخراج شده‌اند که شامل ۲۳۵۳ سانحه هوایی می‌باشد. این داده‌ها شامل متغیرهای ساختاریافته مانند نوع هواپیما، مرحله پرواز، تعداد موتور، تعداد تلفات انسانی و غیره هستند.

۳-۲. تحلیل آماری توصیفی

در این مرحله، از روش‌های آماری توصیفی برای بررسی الگوهای کلی و توزیع متغیرهای مختلف استفاده شده است. ابزارهای آمار توصیفی مانند جداول فراوانی، نمودارهای میله‌ای و نمودارهای چند متغیره برای متغیرهای کلیدی رسم شدند. این تحلیل‌ها به شناسایی روابط اولیه میان متغیرها، مانند تأثیر مرحله پرواز بر شدت سانحه یا ارتباط بین شدت سانحه و نوع موتور کمک می‌کنند. نتایج این بخش به عنوان مبنای تحلیل‌های استنباطی و مدل‌سازی‌های پیش‌بینی در مراحل بعدی مورد استفاده قرار گرفته‌اند.

۳-۳. تحلیل آماری استنباطی

تحلیل روابط بین متغیرهای کیفی موجود در پایگاه داده سوانح هوایی از طریق آمار استنباطی مورد بررسی قرار گرفته است. هدف از به‌کارگیری این روش، بررسی معناداری ارتباط میان متغیر هدف (شدت سانحه) با متغیرهای کمکی است. به منظور آزمون وجود یا عدم وجود ارتباط آماری میان این متغیرها، از آزمون خی دو^{۱۴} استفاده شده است. این آزمون یکی از پرکاربردترین روش‌های آمار استنباطی برای داده‌های طبقه‌ای یا رسته‌ای است و بررسی می‌کند که آیا توزیع مشاهدات در بین دسته‌های مختلف یک متغیر، به‌طور مستقل از متغیر دیگر است یا دو متغیر وابسته به یکدیگر هستند. در این آزمون، فرضیه‌های زیر مورد بررسی قرار می‌گیرد:

- فرض صفر (H_0): بین دو متغیر مورد بررسی رابطه معناداری وجود ندارد (متغیرها مستقل هستند).
 - فرض مقابل (H_1): بین دو متغیر رابطه معناداری وجود دارد (متغیرها مستقل نیستند).
- آماره آزمون خی دو از طریق معادله (۱) محاسبه می‌شود.

$$\chi^2 = \sum_i \frac{(O_i - E_i)^2}{E_i} \quad (1)$$

به طوری که در آن O_i فراوانی‌های مشاهده‌شده و E_i فراوانی‌های مورد انتظار تحت فرض استقلال هستند. مقدار به‌دست‌آمده با مقدار بحرانی در سطح اطمینان ۹۵ درصد و با توجه به درجه آزادی مقایسه می‌شود. اگر مقدار محاسبه‌شده از مقدار بحرانی بیشتر باشد به عبارتی مقدار p کمتر از ۰۰۰۵ باشد، فرض صفر رد شده و وجود رابطه معنادار بین متغیرها تأیید می‌شود. به این ترتیب، آزمون خی دو امکان تحلیل آماری روابط میان متغیرهای طبقه‌ای در داده‌های سوانح را فراهم می‌سازد.

۳-۴. رگرسیون لجستیک

جهت مدل‌سازی بین متغیرهای مستقل و احتمال وقوع سوانح همراه با مرگ و میر، از مدل رگرسیون لجستیک^{۱۵} استفاده شده است. این مدل از جمله مدل‌های پارامتری آماری به شمار می‌آید و به‌ویژه زمانی به کار می‌رود که متغیر وابسته دارای ماهیت دسته‌ای دودویی باشد؛ در این مطالعه،





شدت سانحه به دو دسته اصلی «منجر به تلفات» و «بدون تلفات» طبقه‌بندی شده است.

مدل رگرسیون لجستیک، احتمال وقوع یک رخداد را بر اساس ترکیبی خطی از متغیرهای پیش‌بین محاسبه می‌کند. در این مدل، رابطه بین متغیرهای مستقل و متغیر وابسته از طریق رابطه خطی معادله (۲) محاسبه می‌شود.

$$\log\left(\frac{P}{1-P}\right) = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n \quad (2)$$

به طوری که در آن P احتمال وقوع سانحه منجر به تلفات، X_i متغیرهای مستقل (نظیر نوع موتور، مرحله پرواز، تعداد موتور، نوع ریسک) و β_i ضرایب مدل هستند که با استفاده از روش بیشینه‌سازی درست‌نمایی^{۱۶} برآورد می‌شوند.

۳-۵. مدل‌های یادگیری ماشین

۳-۵-۱. درخت تصمیم

این مدل از جمله روش‌های ناپارامتری در یادگیری ماشین به شمار می‌آید که بدون نیاز به فرض توزیع خاصی برای داده‌ها، امکان مدل‌سازی روابط غیرخطی و پیچیده بین متغیرهای مستقل و متغیر وابسته را فراهم می‌سازد.

مدل درخت تصمیم بر پایه‌ی اصل تقسیم تکراری داده‌ها^{۱۷} عمل می‌کند. در این روش، مجموعه داده‌ها در هر مرحله بر اساس یکی از متغیرهای ورودی یا ویژگی‌ها^{۱۸} به چند زیرمجموعه تقسیم می‌شوند، به گونه‌ای که هر تقسیم^{۱۹} بیشترین جداسازی را میان مقادیر متغیر وابسته ایجاد کند. در واقع، الگوریتم به دنبال یافتن ویژگی‌ای است که

بیشترین توان تمایز^{۲۰} را در پیش‌بینی خروجی دارد. هر تقسیم، یک گره^{۲۱} در ساختار درخت ایجاد می‌کند. گره‌های میانی یا گره‌های تصمیم^{۲۲} نشان‌دهنده‌ی نقاطی هستند که داده‌ها بر اساس مقدار یک ویژگی خاص (مثلاً نوع پرواز یا نوع موتور) به دو یا چند شاخه تقسیم می‌شوند. در نهایت، گره‌های نهایی همان برگ‌ها^{۲۳} شامل برچسب‌های خروجی یا طبقات پیش‌بینی‌شده «منجر به تلفات» یا «بدون تلفات» هستند.

انتخاب ویژگی بهینه در هر گام معمولاً بر اساس معیار نظیر شاخص جینی^{۲۴} بر اساس معادله (۳) یا آنترופی^{۲۵} بر اساس معادله (۴) در درخت‌های طبقه‌بندی محاسبه می‌شود.

$$Gini(t) = 1 - \sum_{i=1}^C [P(i|t) \cdot (1 - P(i|t))] \quad (3)$$

به طوری که در آن $P(i|t)$ نسبت نمونه‌های طبقه‌ی i در گره t است و C تعداد طبقات خروجی می‌باشد. هرچه مقدار $Gini$ کمتر باشد، گره خالص‌تر است.

$$Entropy(t) = \sum_{i=1}^C P(i|t) \log_2(P(i|t)) \quad (4)$$

پس از رشد درخت، برای جلوگیری از بیش‌برازش^{۲۶}، فرآیند هرس^{۲۷} انجام می‌شود تا شاخه‌های غیرضروری حذف و مدل نهایی ساده‌تر و قابل‌تعمیم‌تر گردد.

۳-۵-۲. جنگل تصادفی

جنگل تصادفی یکی از روش‌های یادگیری تجمعی^{۲۸} و از نوع بگینگ^{۲۹} محسوب می‌شود که با

ترکیب چندین درخت تصمیم، مدلی پایدارتر و دقیق‌تر ایجاد می‌کند.

در این روش، مجموعه‌ای از درخت‌های تصمیم بر روی نمونه‌های تصادفی از داده‌های آموزشی ساخته می‌شوند. برای هر درخت، بخشی از داده‌ها به صورت تصادفی و با جایگزینی^{۳۰} انتخاب می‌گردد. همچنین، در هر گره از درخت، فقط تعدادی از متغیرها (ویژگی‌ها) به صورت تصادفی بررسی می‌شوند تا متنوع بودن درخت‌ها حفظ شود. این دو لایه از تصادفی‌سازی باعث می‌شود مدل نهایی خطای واریانس کمتری داشته و نسبت به نویز داده‌ها مقاوم‌تر عمل کند.

پیش‌بینی نهایی در جنگل تصادفی با استفاده از رأی‌گیری اکثریت^{۳۱} برای داده‌های طبقه‌ای و میانگین‌گیری برای داده‌های عددی انجام می‌شود. یعنی هر درخت یک پیش‌بینی ارائه می‌دهد و مدل نهایی تصمیمی می‌گیرد که بیشترین توافق بین درخت‌ها را دارد.

فرمول کلی پیش‌بینی نهایی در مدل درخت‌های طبقه‌ای بر اساس معادله (۵) محاسبه می‌شود.

$$\hat{y} = \text{mode}\{T_1(x), T_2(x), \dots, T_m(x)\} \quad (5)$$

به طوری که در آن $T_i(x)$ خروجی درخت i ام و m تعداد کل درخت‌ها است.

یکی از مزیت‌های مهم جنگل تصادفی، اندازه‌گیری اهمیت ویژگی‌ها^{۳۲} است. این قابلیت نشان می‌دهد هر متغیر تا چه اندازه در بهبود دقت مدل نقش دارد.

۳-۵-۳. درخت تقویت یافته شدید (XGBoost)

این مدل یکی از پیشرفته‌ترین الگوریتم‌های تقویت‌شده^{۳۳} مبتنی بر درخت‌های تصمیم است که با ترکیب چندین درخت و اصلاح خطاهای مدل‌های قبلی، دقت پیش‌بینی بالایی ارائه می‌دهد. این مدل نیز ناپارامتری است و توانایی مدل‌سازی روابط غیرخطی و پیچیده میان متغیرهای مستقل و متغیر وابسته را دارد. در XGBoost، مدل به صورت تجمعی ساخته می‌شود. به این صورت که فرض کنید تا مرحله $(t-1)$ ، پیش‌بینی مدل برای مشاهده i برابر $\hat{y}_i^{(t-1)}$ باشد. در مرحله t ، درخت تصمیم جدید $f_t(x)$ اضافه می‌شود تا خطاهای مرحله قبل کاهش یابد. تابع هدف این مدل بر اساس معادله (۶) تعریف می‌شود.

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (6)$$

به طوری که در آن l تابع زیان^{۳۴} و $\Omega(f_t)$ معیار پیچیدگی مدل است که شامل تعداد برگ‌ها، وزن برگ‌ها و عمق درخت می‌شود و از بیش‌برازش جلوگیری می‌کند. برای حل مسئله بهینه‌سازی، از تقریب بسط تیلور مرتبه دوم با تابع هزینه معادله (۷) استفاده می‌شود.

$$L^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2 + \Omega(f_t) \right] \quad (7)$$

به طوری که در آن g_i و h_i به ترتیب مشتقات مرتبه اول و مرتبه دوم تابع زیان نسبت به





پیش‌بینی فعلی هستند. الگوریتم XGBoost در هر مرحله، درختی می‌سازد که بتواند این تابع هزینه تقریبی را به حداقل برساند.

یکی از مزایای اصلی XGBoost، قابلیت منظم‌سازی^{۳۵} است که کنترل پیچیدگی مدل و جلوگیری از بیش‌برازش را ممکن می‌سازد. علاوه بر این، این الگوریتم برای داده‌های بزرگ و پراکنده^{۳۶} بهینه شده و از تکنیک‌هایی مانند حافظه‌پذیری بهینه برای افزایش سرعت و مقیاس‌پذیری استفاده می‌کند.

۶.۳ ارزیابی مدل‌ها

برای آموزش و ارزیابی مدل‌های پیش‌بینی، مجموعه داده‌ها به دو بخش آموزشی و آزمایشی تقسیم شده‌اند به طور که ۷۰ درصد داده‌ها جهت آموزش مدل و ۳۰ درصد باقی‌مانده برای ارزیابی عملکرد آن مورد استفاده قرار می‌گیرند. این تقسیم‌بندی امکان بررسی توان تعمیم‌پذیری مدل‌ها بر روی داده‌های دیده‌نشده را فراهم می‌کند. عملکرد مدل‌ها با استفاده از شاخص‌های رایج ارزیابی مدل‌های طبقه‌بندی دودویی^{۳۷} مورد بررسی قرار می‌گیرد به طوری که طبقه‌ی مثبت نشان‌دهنده‌ی سوانح منجر به تلفات جانی و طبقه‌ی منفی بیانگر سوانح بدون تلفات جانی است.

نخست، دقت^{۳۸} به عنوان شاخص کلی عملکرد مدل در پیش‌بینی درست نتایج محاسبه می‌شود. این شاخص نسبت تعداد پیش‌بینی‌های درست (اعم از سوانح منجر یا بدون تلفات) به کل نمونه‌های آزمایشی را نشان می‌دهد و از معادله (۸) به دست می‌آید.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

در این رابطه، TP تعداد سوانح دارای تلفات جانی است که مدل آن‌ها را به درستی «منجر به تلفات» پیش‌بینی کرده است و TN تعداد سوانح بدون تلفات جانی است که مدل به درستی آن‌ها را «بدون تلفات» شناسایی کرده است. همچنین، FP بیانگر سوانح بدون تلفات است که به اشتباه «منجر به تلفات» پیش‌بینی شده‌اند و FN نشان‌دهنده‌ی سوانح دارای تلفات جانی است که مدل به غلط آن‌ها را «بدون تلفات» پیش‌بینی کرده است.

شاخص دوم، حساسیت^{۳۹} است که بیانگر توانایی مدل در شناسایی صحیح سوانح منجر به تلفات جانی است. این شاخص از طریق معادله (۹) محاسبه می‌شود.

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (9)$$

شاخص سوم، ویژگی اختصاصیت^{۴۰} است که توانایی مدل در تشخیص صحیح سوانح بدون تلفات جانی را نشان می‌دهد و از طریق معادله (۱۰) به دست می‌آید.

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (10)$$

۴. نتایج


۴-۱. تحلیل آمار توصیفی

در این بخش، به منظور درک الگوی کلی داده‌ها، توصیف آماری متغیرهای اصلی ارائه شده و روابط اولیه میان آن‌ها و متغیر شدت سانحه به عنوان متغیر هدف مورد بررسی قرار گرفته است. داده‌های این پژوهش شامل ۲۳۵۳ مورد سانحه و رخداد هوایی است که در فرایند تحلیل مورد استفاده قرار گرفته‌اند.

جدول ۱. فراوانی و درصد فراوانی شدت سوانح داده‌ها

شدت سانحه	فراوانی	درصد فراوانی
Fatal	۳۴۳	۱۴,۵۷
Minor	۱۸۴	۷,۸۱
None	۱۱۲۰	۴۷,۵۹
Serious	۲۲۱	۹,۳۹
Unknown	۴۸۵	۲۰,۶۱

شکل ۱ توزیع فراوانی مراحل مختلف پرواز در سوانح مورد بررسی را نشان می‌دهد. همان‌گونه که مشاهده می‌شود، بیشترین تعداد سوانح مربوط به مرحله‌ی فرود^{۴۶} با ۶۴۷ مورد است، که حدود یک‌سوم کل داده‌ها را شامل می‌شود. پس از آن، مراحل مسیر میانی پرواز^{۴۷} و برخاستن^{۴۸} به ترتیب با ۴۱۱ و ۳۷۰ مورد در رتبه‌های بعدی قرار دارند. این توزیع نشان می‌دهد که بخش عمده‌ی سوانح در مراحل حرکت اصلی و فرود هواپیما رخ داده است، در حالی که مراحل آغازین صعود و حالت‌های نامشخص، سهم کمتری دارند. این الگو بیانگر آن است که مرحله‌ی فرود و مسیر میانی پرواز ریسک بیشتری برای وقوع سانحه دارند.



شکل ۱. توزیع فراوانی مراحل مختلف پرواز در سوانح

جدول ۱ توزیع شدت سانحه در مجموعه

داده‌های مورد مطالعه را نشان می‌دهد. همان‌گونه که مشاهده می‌شود، بیشترین سهم مربوط به سوانح بدون شدت سانحه^{۴۱} است که با ۱۱۲۰ مورد، حدود ۵۹,۴۷ درصد از کل داده‌ها را شامل می‌شود. پس از آن، سوانح با پیامد مرگ‌بار^{۴۲} با ۳۴۳ مورد و سهم ۵۷,۱۴ درصد قرار دارند. همچنین سطوح شدید^{۴۳} و خفیف^{۴۴} به ترتیب با ۲۲۱ و ۱۸۴ مورد، حدود ۳۹,۹ درصد و ۸۱,۷ درصد از کل سوانح را تشکیل می‌دهند. نکته قابل توجه، سهم قابل توجه گروه نامعلوم^{۴۵} است که ۴۸۵ مورد و حدود ۶۱,۲۰ درصد کل داده‌ها را شامل می‌شود. این امر نشان می‌دهد که بخشی از داده‌ها فاقد اطلاعات صریح در مورد شدت سانحه بوده‌اند و این موارد نمی‌توانند نادیده گرفته شوند، چرا که حذف آن‌ها ممکن است باعث کاهش حجم داده و کاهش دقت تحلیل گردد. در نتیجه، برای تحلیل‌های آماری استنباطی، این گروه به‌عنوان طبقه‌ای مستقل مورد بررسی قرار گرفته است.

در مجموع، تحلیل توصیفی شدت سوانح نشان می‌دهد که تقریباً نیمی از سوانح هوایی منجر به هیچ آسیب جدی نمی‌شوند، در حالی که درصد قابل توجهی از سوانح پیامدهای انسانی داشته‌اند. این یافته‌ها زمینه لازم برای بررسی ارتباط میان شدت سانحه و سایر متغیرهای تاثیرگذار، از جمله مرحله پرواز، نوع موتور و ویژگی‌های هواپیما، را فراهم می‌سازند.



جدول ۲ فراوانی نوع پرنده در سوانح نشان می‌دهد. همان‌گونه که مشاهده می‌شود، بخش عمده‌ی داده‌ها مربوط به سوانح هواپیماهای غیرهلیکوپتر است که ۲۲۵۳ مورد و حدود ۷۵.۹۵ درصد از کل داده‌ها را تشکیل می‌دهند. در مقابل، تنها ۱۰۰ رخداد (۲۵.۴ درصد) مربوط به هلیکوپترها است.

جدول ۲. فراوانی و درصد فروانی نوع پرنده در سوانح

نوع هلیکوپتر	فراوانی	درصد فراوانی
بله	۱۰۰	۴,۲۵
خیر	۲۲۵۳	۹۵,۷۵

جدول ۳ تعداد موتورهای هواپیما در سوانح ثبت‌شده نشان می‌دهد که هواپیماهای تک موتوره و دو موتوره سهمی تقریباً برابر دارند. هواپیماهای با سه و چهار موتور به ترتیب با ۲۸ و ۳۲ مورد بسیار کمتر هستند و کمتر از ۳ درصد کل سوانح را تشکیل می‌دهند.

جدول ۳. فراوانی و درصد فروانی تعداد موتور در

تعداد موتور	فراوانی	درصد فراوانی
۱	۱۱۱۷	۴۷,۴۷
۲	۱۱۷۶	۴۹,۹۷
۳	۲۸	۱,۱۸
۴	۳۲	۱,۳۵

توزیع سوانح بر اساس نوع موتور هواپیما در جدول ۴ قرار دارد. همان‌گونه که مشاهده می‌شود، بیشترین تعداد سوانح مربوط به هواپیماهای با موتور جت^{۴۹} است که ۹۴۵ مورد (حدود ۱.۴۰ درصد) از کل داده‌ها را تشکیل می‌دهند. در جایگاه دوم، هواپیماهای با موتور پیستون^{۵۰} قرار دارند با ۸۷۰

سانحه (حدود ۳۷ درصد)، و در نهایت هواپیماهای توربوپراپ^{۵۱} با ۵۳۸ مورد (حدود ۹.۲۲ درصد) کمترین فراوانی را دارند.

جدول ۴. فراوانی و درصد فروانی نوع موتور در سوانح

نوع موتور	فراوانی	درصد فراوانی
Jet	۹۴۵	۴۰,۱۶
Piston	۸۷۰	۳۶,۹۷
Turboprop	۵۳۸	۲۲,۸۶

بررسی متغیر ریسک سوانح در جدول ۵ نشان می‌دهد که تقریباً نیمی از کل سوانح (۱۱۶۰ مورد) مرتبط با ایمنی باند و عملیات زمینی هواپیما بوده است، این گروه شامل رخدادهای بحرانی در زمان نشست و برخاست مانند خروج از باند، تجاوز به باند، تماس غیر عادی با باند و همچنین حوادث حین جابجایی در فرودگاه است. از این رو، مدیریت هوشمند سطح فرودگاه و مانیتورینگ دقیق عملیات زمینی، نقشی کلیدی در کاهش این سوانح ایفا می‌کند. سهم قابل توجه دیگری (۳۱۵ مورد) به سوانح مرتبط با خرابی سیستم‌ها و قطعات هواپیما اختصاص دارد و نشان می‌دهد که نگهداری فنی و کنترل سیستم‌ها نقش مهمی در کاهش ریسک دارد.

در مقابل، سوانح بسیار شدید مانند برخورد کنترل‌شده با زمین و آتش‌سوزی یا دود بدون برخورد نسبتاً نادر هستند (۵۶ و ۴۲ مورد) و تنها بخش کوچکی از کل رخدادها را تشکیل می‌دهند. این الگو نشان می‌دهد که اکثر سوانح ثبت‌شده ناشی از مشکلات عملیاتی و نقص‌های فنی هستند و سهم سوانح شدید کمتر است.


جدول ۵. فراوانی سوانح هوایی در گروه‌های ریسک

گروه ریسک	تفسیر گروه	فراوانی
CFIT	برخورد کنترل‌شده با زمین	۵۶
F-NI	آتش‌سوزی یا دود بدون برخورد	۴۲
LOC-I	از دست دادن کنترل در حین پرواز	۱۶۸
OTH	سایر عوامل متفرقه	۱۸۷
RS	ایمنی باند و عملیات زمینی	۱۱۶۰
SCF	خرابی سیستم‌ها و قطعات هواپیما	۳۱۵
TURB	حوادث مرتبط با تلاطم هوایی	۱۸۲
UNK	علت نامشخص	۸۱

در ادامه به بررسی ارتباط شدت سانحه با متغیرهای کمکی می‌پردازیم.


نتایج در شکل ۲ نشان می‌دهد که سوانح همراه با مرگ و میر عمدتاً در مراحل صعود اولیه^{۵۲} و نزدیک شدن به فرودگاه^{۵۳} رخ می‌دهد، که این دو مرحله بالاترین ریسک وقوع حوادث شدید و مرگبار را دارند. در مقابل، مراحل فرود و برخاستن بیشتر با سوانح خفیف یا بدون شدت همراه هستند، که نشان‌دهنده سطح نسبی ایمنی در این مراحل است. از تحلیل قبلی به خاطر داریم که علی‌رغم اینکه سوانح در مرحله فرود فراوانی بیشتری نسبت به سایر مراحل پرواز داشت اما مرگ و میر آن‌ها نسبت به سایر مراحل پرواز کمتر است.

این تحلیل نشان می‌دهد که مرحله پرواز و شدت سانحه رابطه دارند و تمرکز ریسک در برخی مراحل خاص می‌تواند مبنای طراحی اقدامات پیشگیرانه و بهبود ایمنی پرواز قرار گیرد.



شکل ۲. توزیع شدت سانحه در مراحل مختلف پرواز

تحلیل شدت سانحه بر اساس نوع موتور در شکل ۳ نشان می‌دهد که موتورهای توربوپراپ بیشترین درصد مرگ و میر (۱۹,۷ درصد) را دارند، در حالی که جت‌ها کمترین درصد مرگ و میر (۹ درصد) را نشان می‌دهند و پیستونی‌ها با ۱۷,۵ درصد در میان قرار دارند. این یافته‌ها نشان می‌دهد که نوع موتور با شدت سانحه رابطه قابل توجهی دارد و هواپیماهای توربوپراپ و پیستونی نسبت به جت‌ها ریسک بالاتری برای مرگ و میر دارند.




شکل ۳. توزیع شدت سانحه در انواع مختلف موتور

تحلیل نوع ریسک و شدت سانحه بر اساس داده‌ها نشان می‌دهد که بیشترین درصد مرگ و میر مربوط به سوانح ناشی از برخورد با موانع زمینی (CFIT)^{۵۴} و از دست رفتن کنترل در حین پرواز (LOC-I)^{۵۵} است که نشان‌دهنده شدت بالای این



نوع سوانح است. در مقابل، سوانح مرتبط با خرابی سیستم‌ها و قطعات هواپیما (SCF)^{۵۶} و رخدادهای مرتبط با ایمنی باند و عملیات زمینی (RS)^{۵۷} عمدتاً با سوانح جزئی یا بدون آسیب همراه هستند و احتمال مرگ و میر در آن‌ها بسیار پایین است.

این تحلیل نشان می‌دهد که شدت سانحه به وضوح با نوع ریسک مرتبط است و سوانح ناشی از برخورد با موانع زمینی و از دست رفتن کنترل در حین پرواز نیازمند اقدامات پیشگیرانه جدی هستند، در حالی که برخی ریسک‌ها بیشتر با آسیب‌های جزئی همراه‌اند. شکل ۴ نمودار درصدی شدت سانحه در هر گروه ریسک را نمایش می‌دهد و این الگوها را به صورت بصری نمایش می‌دهد.



شکل ۴. توزیع شدت سانحه در گروه‌های ریسک مختلف

۴-۲. تحلیل آمار استنباطی

با توجه به نتایج تحلیل‌های توصیفی ارائه‌شده، مشاهده شد که شدت سانحه در سوانح هوایی با برخی ویژگی‌ها مانند نوع ریسک، مرحله پرواز و نوع موتور رابطه دارد. برای ارزیابی آماری این روابط و بررسی این که آیا تفاوت‌های مشاهده‌شده در داده‌ها تصادفی یا غیر تصادفی هستند و نشان‌دهنده الگوی

واقعی در جامعه می‌باشند، تحلیل آمار استنباطی انجام می‌شود.

هدف این بخش، آزمون فرض‌های مرتبط با شدت سانحه و ویژگی‌های پروازی است تا بتوان با استفاده از روش‌های آماری، از جمله آزمون خی-دو معناداری روابط را بررسی کرد.

در این مرحله، فراوانی‌های مشاهده‌شده شدت سانحه در هر دسته‌بندی با فراوانی مورد انتظار تحت فرض صفر مقایسه می‌شوند تا مشخص شود که آیا اختلاف‌های مشهود در داده‌های توصیفی به طور آماری معنادار هستند یا معنادار نیستند. نتایج این آزمون‌ها پایه‌ای برای استنباط‌های علمی و ارائه پیشنهاد‌های عملی برای بهبود ایمنی پرواز فراهم می‌کند و الگوهای بحرانی را که نیازمند توجه ویژه هستند، مشخص می‌نماید.

جدول ۶. نتایج آزمون فرض خی-دو بین متغیر هدف و سایر متغیرهای کمکی

متغیر کمکی	آماره آزمون	درجه آزادی	مقدار پی
مرحله پرواز	۲۸۰٫۵۹	۱۶	۰
نوع موتور	۲۶۲٫۳۲	۸	۰
نوع ریسک	۶۱۱٫۴۶	۱۲	۰
نوع پرنده	۲۷٫۸۲	۴	۰٫۰۰۰۰۱
تعداد موتور	۲۱۰٫۴	۴	۰

پیش از انجام آزمون، به دلیل وجود برخی سلول‌ها با فراوانی کمتر از پنج (محدودیت آزمون خی-دو)، دسته‌های مشابه در متغیرها ادغام شدند تا مفروضات آزمون رعایت شود و نتایج حاصل قابل اعتماد باشد. نتایج آزمون در جدول ۶ نشان دهنده

این است متغیرهای مورد بررسی، ارتباط معناداری ($p\text{-value} < 0.05$) با شدت سانحه دارند.

این یافته‌ها به طور کلی با تحلیل توصیفی پیشین همسو هستند و نشان می‌دهند که متغیرهای ساختاری و عملیاتی، شامل مرحله پرواز، نوع موتور، نوع ریسک، نوع پرنده و تعداد موتور، نقش تعیین‌کننده‌ای در شدت سوانح هوایی دارند.

۳-۴. الگوریتم‌های یادگیری ماشین

به منظور پیش‌بینی احتمال وقوع سوانح مرگبار در داده‌های سوانح هوایی، چهار مدل یادگیری ماشین شامل درخت تصمیم، جنگل تصادفی، رگرسیون لجستیک و درخت تقویت یافته شدید (XGboost) مورد استفاده قرار گرفتند. عملکرد هر مدل بر اساس سه شاخص دقت کلی، حساسیت و اختصاصیت مورد ارزیابی قرار گرفت. نتایج حاصل در جدول ۷ ارائه شده است.

جدول ۷. نتایج مدل‌های یادگیری ماشین در پیش‌بینی نوع

شدت سانحه

مدل	دقت	حساسیت	اختصاصیت
رگرسیون لجستیک	۱۲,۵	۴۴,۱	۰,۰۵
درخت تصمیم	۸۷,۴	۵۵,۸	۹۴,۵
جنگل تصادفی	۸۸,۵	۶۴,۷	۹۳,۸
درخت تقویت یافته شدید	۸۷,۶	۶۷,۶	۹۲,۱

بر اساس نتایج جدول ۷، مدل XGboost عملکرد بهتری را در میان مدل‌های مورد استفاده نشان داده است. این مدل با دستیابی به دقت کلی ۰,۸۷۶ و حساسیت ۰,۶۷۶، توانسته است تعادلی مناسب میان تشخیص درست سوانح مرگبار و

غیرمرگبار برقرار کند. در واقع، حساسیت بالاتر این مدل نسبت به سایر روش‌ها نشان می‌دهد که این مدل توانایی بیشتری در شناسایی صحیح رخداد‌های مرگبار دارد.

در مقابل، مدل جنگل تصادفی هرچند دقت بالاتری دارد (۰,۸۸۵)، اما از نظر معیار حساسیت (۰,۶۷۴) ضعیف‌تر از XGBoost عمل کرده است. این امر نشان می‌دهد که این مدل در تشخیص سوانح مرگبار بخشی از موارد را از دست داده است و در مقایسه با XGboost از پایداری کمتری برخوردار است.

مدل درخت تصمیم نیز عملکرد قابل قبولی از نظر دقت کلی ارائه کرده ولی از نظر معیار حساسیت (۰,۵۵۸) نتایجی ضعیف‌تری نسبت به جنگل تصادفی و XGboost داشته است؛ این مدل، به دلیل استفاده از تک درخت، کارایی لازم را در داده‌های پیچیده‌تر از دست داده است.

در نهایت، مدل رگرسیون لجستیک ضعیف‌ترین عملکرد را نشان داده است. دقت پایین (۰,۱۲۵) و حساسیت (۰,۴۴۱) بیانگر آن است که این مدل آماری سنتی قادر به تفکیک مؤثر بین سوانح مرگبار و غیرمرگبار نبوده است. علت اصلی این ضعف را می‌توان در ماهیت غیرخطی و پیچیده روابط بین متغیرها در داده‌های سوانح هوایی دانست، در حالی که رگرسیون لجستیک بر فرض روابط خطی میان متغیرهای مستقل و متغیر وابسته تکیه دارد.

به طور کلی، می‌توان نتیجه گرفت که مدل XGboost با توجه به دقت کلی بالا، حساسیت مناسب و پایداری بیشتر در تشخیص الگوهای





پیچیده، بهترین مدل برای پیش‌بینی سوانح مرگبار در این مطالعه محسوب می‌شود.

۵. نتیجه‌گیری و پیشنهاد

در این پژوهش با هدف تحلیل آماری و پیش‌بینی شدت سوانح هوایی و بررسی عوامل مؤثر بر مرگبار بودن آن‌ها، از ترکیبی از روش‌های آماری و مدل‌های یادگیری ماشین استفاده شد.

داده‌های مورد استفاده شامل مجموعه‌ای از متغیرهای فنی و عملیاتی از جمله مرحله پرواز، نوع موتور، گروه ریسک، نوع وسیله پرنده و تعداد موتورها بودند. پیش از مدل‌سازی، داده‌ها مورد تحلیل آماری قرار گرفتند تا ویژگی‌های کلیدی و الگوهای اولیه آشکار شوند.

در بخش تحلیل توصیفی، توزیع داده‌ها نشان داد که بیشترین فراوانی سوانح از مراحل پرواز هنگام فرود، مسیر میانی پرواز و برخاستن رخ داده و سوانح مرگبار عموماً در گروه‌های ریسک برخورد کنترل شده با زمین و از دست دادن کنترل در حین پرواز مشاهده شده است. همچنین تحلیل فراوانی‌ها بیانگر آن بود که گرچه سوانح با شدت‌های مختلف به‌طور گسترده‌ای ثبت شده‌اند، اما سهم سوانح منجر به تلفات کمتر ولی از نظر پیامد بسیار مهم‌تر است.

در ادامه، با استفاده از روش‌های استنباطی و مدل‌سازی یادگیری ماشین، رابطه‌ی میان متغیرهای ورودی و پیامد سانحه مورد بررسی قرار گرفت. چهار مدل اصلی شامل رگرسیون لجستیک، درخت تصمیم، جنگل تصادفی و XGboost

پیاده‌سازی و ارزیابی شدند. نتایج مدل‌ها در جدول ۷ نشان داد که مدل XGboost با دقت کلی ۰,۸۷۶، حساسیت ۰,۶۷۶ بهترین عملکرد را در میان سایر الگوریتم‌ها داشت. این مدل توانست تعادلی بهینه میان شناسایی صحیح سوانح مرگبار و جلوگیری از پیش‌بینی‌های نادرست برقرار کند.

در مقایسه، مدل جنگل تصادفی با دقت ۰,۸۸۵ و حساسیت ۰,۶۴۷ عملکرد قابل قبول اما نسبتاً پایین‌تری در تشخیص سوانح شامل مرگ و میر داشت. مدل درخت تصمیم با استفاده از تک درخت دقت ۰,۸۷۴ و حساسیت ۰,۵۵۸ عملکرد ضعیف‌تری را ارائه داد. درنهایت، مدل رگرسیون لجستیک با دقت پایین‌تر (۰,۱۲۵) نشان داد که روابط میان متغیرها ماهیت خطی نداشته و نیاز به مدل‌های غیرخطی و ترکیبی احساس می‌شود.

بر اساس تحلیل آماری، می‌توان نتیجه گرفت که متغیرهایی نظیر مرحله پرواز و نوع موتور تأثیر معناداری بر احتمال مرگبار بودن سوانح دارند؛ به‌ویژه مراحل بحرانی پرواز مانند صعود اولیه و نزدیک شدن به فرودگاه بیشترین ارتباط را با سوانح منجر به مرگ و میر دارند. این یافته‌ها می‌تواند به تدوین دستورالعمل‌های ایمنی دقیق‌تر کمک کند.

با وجود نتایج امیدوارکننده، پژوهش حاضر دارای محدودیت‌هایی نیز هست. نخست آنکه، احتمال وجود نقص در گزارش‌دهی یا خطای انسانی در ثبت داده‌های سوانح وجود دارد. مورد دوم آنکه، داده‌ها ممکن است نماینده‌ی کامل همه‌ی سوانح نباشند.

۶. منابع

- [1] A. Nanyonga, U. Turhan, and G. Wild, "A Systematic Review of Machine Learning Analytic Methods for Aviation Accident Research," *Sci*, vol. 7, no. 3, p. 124, Sep. 2025.
- [2] M. Caetano, "Aviation accident and incident forecasting combining occurrence investigation and meteorological data using machine learning", *Aviation*, vol. 27, no. 1, pp. 47–56, Mar. 2023.
- [3] R. A. Burnett and D. Si, "Prediction of injuries and fatalities in aviation accidents through machine learning," in *Proc. Int. Conf. Compute and Data Analysis*, May 2017, pp. 60–68.
- [4] T. T. İnan and N. G. İnan, "Analysis of the primary factors affecting the most fatal aviation accidents: a machine learning approach," *Reliability: Theory & Applications*, vol. 17, no. 1 (67), pp. 164–177, 2022.
- [5] T. T. İnan and N. G. İnan, "The analysis of fatal aviation accidents more than 100 dead passengers: an application of machine learning," *Opsearch*, vol. 59, no. 4, pp. 1377–1395, 2022.
- [6] D. V. Silagyi II and D. Liu, "Prediction of severity of aviation landing accidents using support vector machine models," *Accident Analysis & Prevention*, vol. 187, p. 107043, 2023.
- [7] F. Omrani, H. Etemadfar, and R. Shad, "Assessment of aviation accident datasets in severity prediction through machine learning," *J. Air Transp. Manage.*, vol. 115, p. 102531, 2024.
- [8] V. de Vries, "Classification of Aviation Safety Reports using Machine Learning," in *Proc. 2020 Int. Conf. Artificial Intelligence and Data Analytics for Air Transportation (AIDA-AT)*, Singapore, pp. 1-6, Feb. 2020.
- [9] A. Nanyonga, K. F. Joiner, U. Turhan, and G. Wild, "Deep Learning Approaches for Classifying Aviation Safety Incidents: Evidence from Australian Data," *AI*, vol. 6, no. 10, p. 251, 2025.
- [10] X. Zhang and S. Mahadevan, "Ensemble machine learning models for aviation incident

در پیش‌بینی شدت سوانح به کمک

الگوریتم‌های یادگیری ماشین نیز پژوهش‌ها [۷-۸] دقت تقریبی ۸۰ درصد را به کمک مدل‌های RF و SVM بدست آورده‌اند. با این حال سایر مطالعاتی که از مدل‌های پیچیده‌تر مانند شبکه‌های عصبی عمیق [۹] و مدل‌های ترکیبی [۱۰] استفاده کرده‌اند، دقت بالاتری در حدود ۹۰ درصد گزارش نموده‌اند.

برای پژوهش‌های آتی پیشنهاد می‌شود از داده‌های چندمنبعی و ترکیبی شامل شرایط جوی، نوع مأموریت، سوابق تعمیر و نگهداری و داده‌های عملکرد پروازی نیز استفاده شود. همچنین، استفاده از مدل‌های پیشرفته‌تر مانند شبکه‌های عصبی عمیق (DNN)^{۵۸}، الگوریتم‌های پیشرفته‌تر و مدل‌های ترکیبی چندسطحی می‌تواند دقت پیش‌بینی را افزایش دهد.

در نهایت، نتایج این پژوهش برای سازمان‌های هوانوردی، سازمان هواپیمایی کشور، مراکز ایمنی پرواز و نهادهای سیاست‌گذار حائز اهمیت است. به‌کارگیری مدل‌های داده‌محور و تحلیل‌های آماری مشابه می‌تواند در پیشگیری از سوانح، بهبود آموزش خدمه، افزایش ایمنی عملیاتی و طراحی سیستم‌های هشدار هوشمند نقش تعیین‌کننده‌ای ایفا کند. در واقع، این نوع تحلیل‌ها گامی مؤثر در جهت گذار از تحلیل‌های توصیفی به تصمیم‌گیری مبتنی بر داده^{۵۹} در صنعت هوانوردی به‌شمار می‌آید.



- making methods," J. Aeronaut. Eng., vol. 25, no. 1, pp. 154-180, 2023 (in Persian).
- [20] J. Raei, H. R. Zarghami, and A. A. Zand, "Analysis of I.R.I.A.A Aviation Accidents from 1989 to 2019 Using Data Mining Tools," Mil. Sci. Tactics, vol. 17, no. 56, pp. 29-50, 2021 (in Persian).
- [21] M. Rahnema and S. Khansalari, "Analysis of Weather-Related Aviation Accidents in Iran Using ASN Information and ERA5 Reanalysis Data," Nivar, vol. 49, no. 130-131, pp. 100-121, 2025 (in Persian).

۷. پی‌نوشت

1. Data Science
2. Machine learning
3. International Civil Aviation Organization
4. Text Mining
5. Natural language processing
6. Decision Tree
7. Random Forest
8. Support Vector Machines
9. Neural Networks
10. Ensemble Methods
11. Radial Basis Function
12. Convolutional Neural Network
13. Long Short-Term Memory
14. Chi-Square
15. Logistic Regression
16. Maximum Likelihood Estimation
17. Recursive Partitioning
18. Features
19. Split
20. Discriminative Power
21. Node
22. Decision Nodes
23. Leaf Nodes
24. Gini Index
25. Entropy
26. Overfitting
27. Pruning
28. Ensemble Learning
29. Bagging
30. Bootstrap Sampling
31. Majority Voting
32. Feature Importance
33. Boosting
34. Loss Function
35. Regularization
36. Sparse Data
37. Binary Classification
38. Accuracy
39. Sensitivity
40. Specificity
41. None

- risk prediction," Decision Support Syst., vol. 116, pp. 48–63, 2019.
- [11] A. O. Alkhamisi and R. Mehmood, "An Ensemble Machine and Deep Learning Model for Risk Prediction in Aviation Systems," in Proc. 2020 6th Conf. Data Science and Machine Learning Applications (CDMA), Riyadh, Saudi Arabia, pp. 54-59, Mar. 2020.
- [12] M. Monika, S. Verma, P. Kumar, and M. Kakran, "A stacking model for aviation high risk event decision making," in J. Phys.: Conf. Ser., vol. 1950, no. 1, p. 012069, IOP Publishing, 2021.
- [13] A. Khattak, P. W. Chan, F. Chen, H. Peng, and C. Mongina Matara, "Missed Approach, a Safety-Critical Go-Around Procedure in Aviation: Prediction Based on Machine Learning-Ensemble Imbalance Learning," Advances in Meteorology, vol. 2023, no. 1, p. 9119521, 2023.
- [14] S. Wu, Q. Yuan, Z. Yan, and Q. Xu, "Analyzing accident injury severity via an extreme gradient boosting (XGBoost) model," J. Adv. Transp., vol. 2021, no. 1, p. 3771640, 2021.
- [15] X. Shi, Y. D. Wong, M. Z. F. Li, C. Palanisamy, and C. Chai, "A feature learning approach based on XGBoost for driving assessment and risk prediction," Accident Anal. Prev., vol. 129, pp. 170–179, 2019.
- [16] X. Shen and S. Wei, "Application of XGBoost for Hazardous Material Road Transport Accident Severity Analysis," IEEE Access, vol. 8, pp. 206806–206819, 2020.
- [17] Y. Xing, Y. Wu, S. Zhang, L. Wang, H. Cui, B. Jia, and H. Wang, "Discovering latent themes in aviation safety reports using text mining and network analytics," Int. J. Transp. Sci. Technol., vol. 16, pp. 292–316, 2024.
- [18] A. Ahadh, G. V. Binish, and R. Srinivasan, "Text mining of accident reports using semi-supervised keyword extraction and topic modeling," Process Saf. Environ. Prot., vol. 155, pp. 455–465, 2021.
- [19] A. Nosrati Malekjahan, A. Husseinzadeh Kashan, and B. Ostadi, "Analysis of Iran's civil aviation accidents and serious incidents from 1979 to 2021 using failure mode and effects analysis and multi-attribute decision

۱۵۸

سال ۱۴۰۴ - شماره ۲

پاییز و زمستان ۱۴۰۴

نشریه علمی



تحلیل آماری و پیش‌بینی شدت سوانح هوایی با استفاده از الگوریتم‌های یادگیری ماشین: مطالعه‌ای بر داده‌های سوانح آمریکا در پایگاه داده ICAO

- 42. Fatal
- 43. Serious
- 44. Minor
- 45. Unknown
- 46. Landing
- 47. Enroute
- 48. Take-off
- 49. Jet
- 50. Piston
- 51. Turboprop
- 52. Initial Climb
- 53. Approach
- 54. Controlled Flight into Terrain
- 55. Loss of Control In-flight
- 56. System / Component Failure
- 57. Runway Safety
- 58. Deep Neural Networks
- 59. Data-Driven Safety Management

۱۵۹

سال ۱۴ - شماره ۲

پاییز و زمستان ۱۴۰۴

نشریه علمی



تحلیل آماری و پیش‌بینی شدت سوانح هوایی با استفاده از الگوریتم‌های یادگیری ماشین: مطالعه‌ای بر داده‌های سوانح آمریکا در پایگاه داده ICAO