

【航空管理与安全】

基于 GM-BP 的机场管制系统风险预测

侣庆民, 赵永航, 隋玉鲲, 李俊艳

(郑州航空工业管理学院 民航学院, 河南 郑州 450046)

摘 要: 机场管制是航空运输过程中至关重要的一环, 其安全性对航空运输的可持续发展至关重要。针对机场管制系统运行过程中可能出现的风险进行预测, 依据 SHELL 模型, 构建管制系统风险指标体系, 从体系中选取影响较大的冲偏出跑道、跑道侵入、跑道外接地三类事件, 在传统的灰色预测 GM(1, 1) 模型的基础上, 加入 BP 神经网络组建 GM-BP 灰色神经网络预测模型进行风险预测。预测结果显示, 所采用的 GM-BP 预测模型预测的精度较高, 同时得益于其对数据的综合处理能力和对复杂系统的有效建模能力, 在机场管制系统运行风险预警方面有着广泛的适用场景, 为后续针对可能出现的风险实施风险管理提供了科学的参考。

关键词: 灰色理论; 神经网络; 风险预测; 航空安全

中图分类号: V 35 **文献标识码:** A **DOI:** 10.13486/j.issn.2097-4973.2024.01.010

0 引言

航空运输是现代国际运输的主要方式之一, 是一个国家经济发展的重要体现。中国民航局 2023 年 6 月主要生产指标统计显示, 2023 年上半年全行业完成旅客运输量 2.84 亿人次, 比上年同期增长 140.2%, 恢复至 2019 年上半年的 88.2%, 起降架次数达到 558.3 万架次, 增长 60.3%, 恢复至 2019 年上半年的 98.3%^[1]。数据显示, 中国民航事业正在不断地恢复, 航空运输业将迎来新一轮的发展。在此快速发展中, 航空运输安全问题至关重要。机场管制作为确保航空运输安全与顺畅的重要环节, 其安全性对航空运输的可持续发展至关重要。

随着民航业的发展和空中交通流量的不断增多, 机场管制的复杂性和难度不断上升, 传统的基于规则和流程的管制方式面临着很大的压力和挑战, 已经难以应对现代航空业的需求^[2]。因此, 面向机场管制系统的风险管理研究应运而生, 该研究旨在通过对系统运行过程中可能出现的风险进行预测、识别、评估与控制以提高机场管制的效率和安全性, 对整个航空运输过程有着至关重要的影响, 成为一个新的研究方向。

目前对于管制系统的风险研究, 主要集中在风险评估与风险控制方面。如在风险评估方面, 张俊强等^[3]提出基于风险信息熵的危险天气条件下终端区管制系统风险评估模型, 分析危险天气条件下管制系统的运行过程, 建立管制系统运行中的熵流模型与危险天气下终端区管制风险评估指标体系, 实现对终端区管制的风险评估; 张豫翔等^[4]在模糊层次分析法的基础上, 结合云模型, 建立了风险评估模型, 就迫降方

收稿日期: 2024-04-11

基金项目: 河南省高等学校青年骨干教师培养计划(2020GGJS174); 河南省高等学校重点科研项目(24A620005)

第一作者简介: 侣庆民(1983—), 男, 山东菏泽人, 副教授, 博士, 主要从事系统安全与风险评价、公共安全与应急管理研究。E-mail: siqingmin@zua.edu.cn

面进行了风险评估;李昂等^[5]提出一种基于相互依存网络和 SVM 的控制系统运行态势评估方法,并以点距平稳运行分类边界的距离为评价控制系统运行情况的指标,对管制系统运行态势进行了评估。在风险控制方面,张兆宁和董环环^[6]在风险控制阶段引入折叠突变模型,确定系统突变特征耦合风险因素对系统状态的影响程度,并基于 Vander Pol-Duffing 方程,应用多尺度法设计管制系统内部阻尼调节系数和外部影响因素幅值系数两个风险控制器,确定风险控制要素;张兆宁和李文雅^[7]基于过程方法识别进近管制系统中的风险,并确定相应的风险控制策略,通过构建虚拟风险节点扩展的风险控制网络图,建立进近管制系统的风险控制网络模型,确定风险控制的最优组合方案。风险评估和风险控制方面研究较多,但风险预测方面的研究在文献数量及方法上存在不足。毛继志等^[8]基于文本挖掘构建了贝叶斯网络对空管不正常事件风险进行预测,但其分析年份较短,预测结果缺乏普适性。为更好地对机场管制系统的风险进行预测研究,本文针对现有的风险预测方法进行学习,如 SU 等^[9]提出了一种结合 Prophet 和长短期记忆(LSTM)网络的混合预测模型,捕捉事件的周期性特征和时间依赖性,以对航空风险进行预测;Kumari 等^[10]结合人工神经网络模型和贝叶斯网络模型来预测事故的原因和后果以及发生的概率;俞思轩等^[11]提出一种基于稀疏去噪自编码器(SDAE)神经网络的预测方法,对通航风险进行了预测。根据上述风险预测方法的研究可知,神经网络模型在风险预测方面有着较好的适用性。

风险预测是风险管理过程的重要部分,为弥补机场管制系统风险预测研究的不足,本文结合近 20 年的不安全事件数据并将 BP 神经网络模型作为对机场管制系统进行风险预测研究一个重要部分,对机场管制系统运行过程中可能出现的风险进行预测研究。首先依据 SHELL 模型,构架管制系统运行风险指标体系,从体系中选取冲偏出跑道、跑道侵入、跑道外接地三类事件,以 1999—2016 年事故数量为实验数据,在传统的灰色预测 GM(1,1)模型的基础上,加入 BP 神经网络组建 GM-BP 预测模型,实现对不安全事件的风险预测。同时以预测数据为参考进行风险控制等措施的实施,希望有助于提高风险管理的效率以及管理资源的合理分配。

1 模型介绍

1.1 灰色预测模型

灰色理论是在研究对象仅有部分信息已知、部分信息未知的情况下,通过部分已知信息完成对系统对象发展的分析、评价、预测^[12]。灰色预测 GM(1,1)模型有所需样本少、数据较为准确的优点^[13]。在民航领域,由于致使管制系统不安全事件发生的因素很多,但已知的数据较少,因此灰色预测 GM(1,1)模型适用于研究管制系统的运行安全。GM(1,1)模型构建的具体步骤如下:

(1) 设原始数据为 $x^{(0)} = [x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)]$ 。

(2) 首先对原始数据 $x^{(0)}$ 进行一次累加生成处理,得到累加生成序列: $x^{(1)} = [x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(k)]$,其中 $x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i)$ 。计算其紧邻序列值 $z^{(1)} = [z^{(1)}(2), z^{(1)}(3), \dots, z^{(1)}(k)]$,其中

$$z^{(1)}(k) = \frac{1}{2}x^{(1)}(k) + \frac{1}{2}x^{(1)}(k-1), k = 2, 3, \dots, n。$$

建立一阶微分线性方程,即灰色微分方程,得到 GM(1,1)模型的均值形式: $x^{(0)}(k) + ax^{(1)}(k) = b$ 。通过 GM(1,1)模型相应的白化微分方程 $\frac{dx^{(1)}}{dt} + ax^{(1)} = b$ 。式中: a 表示发展系数,反映了 $\hat{x}^{(1)}$ 和 $\hat{x}^{(0)}$ 的发展态势; b 表示灰色作用量或者内生控制灰数,是从行为序列中挖掘出来的数据,反映的是数据变化的关系,其确切内涵是灰的。设 \hat{a} 为待估参数向量,令 $\hat{a} = \begin{bmatrix} a \\ b \end{bmatrix}$,利用最小二乘法求解可得 $\hat{a} = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{Y}$ 。式中: \mathbf{B} 矩阵反映了白化数据序列的累加值之间的相关关系, \mathbf{Y} 矩阵反映了白化数据序列的一阶微分值。 \mathbf{B} 、 \mathbf{Y} 分别为

$$B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix}, Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix}。$$

建立 GM(1,1) 模型的时间响应式,即预测模型

$$\begin{cases} \hat{x}^{(1)}(k+1) = (x^{(0)}(1) - \frac{b}{a})e^{-ak} + \frac{b}{a}, \\ \hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k)。 \end{cases}$$

式中, $k = 0, 1, 2, \dots, n$ 。

(3) 采用后验差检验来检验 GM(1,1) 模型预测可靠度,原始序列均值 $\bar{x}^{(0)} = \frac{1}{n} \sum_{k=1}^n x^{(0)}(k)$ 。计算的

原始序列标准差 $S_1 = \sqrt{\frac{\sum [x^{(0)}(k) - \bar{x}^{(0)}]^2}{n-1}}$ 。残差序列的均值 $\Delta^{(0)} = \frac{1}{n} \sum_{k=1}^n [x^{(0)}(k) - \hat{x}^{(0)}(k)]$ 。计算绝对

误差序列的标准差 $S_2 = \sqrt{\frac{\sum [\Delta^{(0)}(k) - \bar{\Delta}^{(0)}]^2}{n-1}}$ 。计算后验差比值为 $C = \frac{S_2}{S_1}$ 。

1.2 BP 神经网络模型

人工神经网络(Artificial Neural Networks)是模仿生物神经网络的一种数学模型^[14],包含输入层、隐含层、输出层。输入层的数据经过一定的处理,结合其他输入到神经元的数据,经过神经元的插值调整,最后利用特定函数将其输出,即人工神经网络就是一个将输入的多个非线性模型进行加权处理,最终生成一个输出模型的过程。其拓扑结构如图 1 所示。




图 1 典型 BP 神经网络拓扑结构

(1) 依据图 1 典型 BP 神经网络拓扑结构,在输入层和输出层确定数据后,需要在隐含层调整连接权重,在数学模型中可以理解为经过输入层生成的数据与输出层给定的确定值存在一定的误差,使用最小化均方根差定义损失函数

$$L(e) = \frac{1}{2} S \cdot S_E = \frac{1}{2} \sum_{j=0}^k e_j^2 = \frac{1}{2} \sum_{j=0}^k (z_j - y_j)^2。$$

式中: L 表示损失函数的值,代表了模型预测值与真实值之间的差异; e 表示误差,代表了单个样本的预测值与真实值之间的差异; S 表示样本数,代表了训练集中样本的数量; S_E 表示平均误差,代表了所有样本的平均误差; j 表示样本索引,代表了训练集中每个样本的编号; z_j 表示模型对第 j 个样本的预测值; y_j 表示第 j 个样本的真实值。

(2) 为确定 L 的最小值,使用随机梯度下降法,在数学模型中定义如下变量含义: ω_{ij}^1 表示输入层节点 i 到输出层节点 j 的连接权重; ω_{ij}^2 表示隐含层节点 i 到输出层节点 j 的连接权重; x_i 表示输入层节点 i 的输入; s_i^2 表示输出层节点 i 的输入; s_j^1 表示隐含层节点 j 的输入; s_j^2 表示输出层节点 j 的输入。依据链式法则,有

$$\frac{\partial L}{\partial \omega_{ij}^1} = \frac{\partial L}{\partial s_j^1} \cdot \frac{\partial s_j^1}{\partial \omega_{ij}^1}。 \tag{1}$$

已知 $s_j^1 = \sum_{i=1}^m x_i \cdot \omega_{ij}^1$,带入式(1),得 $\frac{\partial L}{\partial \omega_{ij}^1} = x_i \cdot \frac{\partial L}{\partial s_j^1}$,即

$$\frac{\partial L}{\partial s_j^1} = \sum_{i=1}^k \frac{\partial L}{\partial s_i^2} \cdot \frac{\partial s_i^2}{\partial s_j^1}。 \tag{2}$$

由于 $s_i^2 = \sum_{j=0}^n \theta(s_j^1) \cdot \omega_{ij}^2$, 则

$$\frac{\partial s_i^2}{\partial s_j^1} = \frac{\partial s_i^2}{\partial \theta(s_j^1)} \cdot \frac{\partial \theta(s_j^1)}{\partial s_j^1} = \omega_{ji}^2 \cdot \theta'(s_j^1)。$$

带入式(2) 可得

$$\frac{\partial L}{\partial s_j^1} = \sum_{i=1}^k \frac{\partial L}{\partial s_i^2} \cdot \omega_{ji}^2 \cdot \theta'(s_j^1) = \theta'(s_j^1) \cdot \sum_{i=1}^k \frac{\partial L}{\partial s_i^2} \cdot \omega_{ji}^2。$$

记 $\delta_i^1 = \frac{\partial L}{\partial s_j^1}$, 则隐含层 $\delta_j^1 = \theta'(s_j^1) \cdot \sum_{i=1}^k \delta_i^2 \cdot \omega_{ji}^2$, 输出层 $\delta_i^2 = \frac{\partial L}{\partial s_i^2} = \frac{\partial \sum_{j=0}^k \frac{1}{2} (\bar{y}_j - y_j)^2}{\partial s_i^2} = e_i \cdot \frac{\partial \bar{y}_j}{\partial s_i^2}。$

接下来进行反向传播, 将误差 e_i 反向输入, 相当于输出层与输入层互换, 输入的值是误差 e_i , 得到输出层 δ , 输出层 δ 再根据连接权重向隐含层输出。待反向传播得到所有输出层 δ 后, 权重更新。

1.3 GM-BP 模型

为提高单一 GM(1,1)模型的预测精度, 将处理后的部分数据作为输入数据在 BP 神经网络模型中进行训练, 调整网络权重和偏置, 以提高预测的准确性。在训练完成后, 将 GM(1,1)模型预测所得的所有预测数据导入 BP 神经网络模型中, 使用确定的网络权重, 输出预测结果。其结合方式如图 2 所示。



图 2 GM-BP 模型结合方式

2 管制系统运行风险指标体系

2.1 SHEL 模型

SHEL 模型强调人在民用航空系统中的核心地位, 其中 S 为软件 (Software), H 为硬件 (Hardware), E 为环境 (Environment), L 为其他人 (Liveware)。人位于中心位置, 与软件、硬件、环境、其他人形成相互关系, 共同影响着系统的安全运行^[15]。

2.2 跑道滑跑风险预测指标体系

本文依据 SHEL 模型, 从管制人员行为、跑道侵入、冲偏出跑道、跑道外接地、跑道环境五个方面研究跑道安全风险, 结合现有学者的研究基础^[16], 与一线工作人员、行业相关专家交流沟通后, 建立起管制系统运行风险指标体系, 如表 1 所示。

表 1 管制系统运行风险指标体系

风险类别	风险源	风险类别	风险源
管制人员行为 F_1	管制员判断失误 F_{11}	冲偏出跑道 F_3	航空器冲出跑道端口 F_{31}
	管制员操作违规 F_{12}		航空器出现侧滑导致偏移 F_{32}
	注意力不集中 F_{13}	跑道外接地 F_4	未按指令落地指定跑道 F_{41}
	管制移交不充分、协调不足 F_{14}		落在了滑行道上 F_{42}
跑道侵入 F_2	有航空器未及时从跑道撤离 F_{21}	跑道环境 F_5	暴雨等极端天气 F_{51}
	航空器或车辆进入正在使用的跑道 F_{22}		跑道能见度低 F_{52}
	航空器或车辆未按指令行驶 F_{23}		跑道污染 F_{53}
			其他极端环境 F_{54}

根据波音公司对 2013—2022 年民航商用飞机的统计数据, 尽管跑道着陆阶段只占总飞行时间的 1%, 却发生了占比高达 31% 的致命事故。可知着陆阶段是飞行中极具危险性的阶段, 因此本文针对着陆

阶段所涉及的跑道侵入、冲偏出跑道、跑道外接地三种机场跑道不安全事件进行风险预测研究。

3 基于 GM-BP 的仿真预测

本文以 GM-BP 模型为方法,从管制系统运行风险指标体系中选取冲偏出跑道、跑道侵入、跑道外接地三类机场管制风险事件数量为研究对象,以 1999—2019 年的中国民航不安全事件发生次数为样本数据,进行次数预测。

3.1 GM(1,1)预测

1999—2019 年冲偏出跑道、跑道侵入、跑道外接地三类事件发生次数的数据如表 2 所示。从表中数据可知,三类事件数量整体呈上升趋势,这与民航行业发展迅速,航班数量逐渐增长有密不可分的关系。

表 2 1999—2019 年三类事件数据

年份	跑道侵入	冲偏出跑道	跑道外接地	总和	年份	跑道侵入	冲偏出跑道	跑道外接地	总和
1999	1	0	0	1	2010	14	6	1	21
2000	1	1	0	2	2011	13	4	2	19
2001	3	2	1	6	2012	16	7	2	25
2002	3	3	0	6	2013	15	7	4	26
2003	3	2	0	5	2014	20	8	3	31
2004	7	3	0	10	2015	22	10	4	36
2005	10	3	1	14	2016	19	9	6	34
2006	6	2	1	9	2017	20	11	7	38
2007	11	3	1	15	2018	23	10	9	42
2008	16	4	2	22	2019	25	11	9	45
2009	16	4	1	21					

注:数据来源于 <http://asn.flight safety.org/>,查询时间 2023 年 3 月

以 1999—2007 年三类事件发生次数的数据为基础对三类事件做 GM(1,1)预测,预测其 2008—2016 年发生次数的数据,并将所得结果与实际值作对比,结果如表 3 所示。由表 3 可知,该阶段预测值与实际值对比,除 2016 年数据出现较大偏差外,其余年份整体较为接近。为验证该部分灰色模型预测的可信性,利用 1.1 部分中提及的后验差检验方法对表 3 数据进行可靠度检验。经检验,三类事件预测数据的后验差比值 C 为 0.37741,处在 $[0.35, 0.5]$ 的范围内,精度合格。

表 3 灰色 GM(1,1)预测的 2010—2016 年三类事件预测值与原始数据对比

年份	实际值	预测值	误差	年份	实际值	预测值	误差
2008	22	18.2741	3.7259	2013	26	28.9816	2.9816
2009	21	19.5917	1.4083	2014	31	32.5962	1.5962
2010	21	20.4799	-0.5201	2015	36	36.6987	0.6987
2011	19	22.9735	-3.9735	2016	34	41.3623	7.3623
2012	25	25.7920	0.7920				

由于本文所用 GM-BP 模型需以灰色预测值为输入数据进行 BP 神经网络模型预测,因此在验证 GM(1,1)模型预测精度之后,继续预测 2017—2021 年三类事件的发生次数,经过 GM(1,1)模型对三类事件发生次数的预测结果如表 4 所示。由于受新冠肺炎影响,2020 年、2021 年航空运输业产生了较大波动,其相关数据出现了较大的失真情况,因此只对比 2017—2019 年的预测数据与实际值。经过对比,发现

2017—2019 年预测数据已经与实际数据出现较大偏差,说明单一的 GM(1,1)模型在进行长期预测时其精度难以保证,需要对其进行改良以提高其预测精度。

表 4 灰色 GM(1,1)预测的 2017—2021 年三类事件预测值

年份	实际值	预测值	误差	年份	实际值	预测值	误差
2017	38	46.6720	8.6720	2020	—	67.5676	—
2018	42	52.7278	10.7278	2021	—	76.6518	—
2019	45	59.6470	14.6470				

3.2 BP 神经网络预测

3.2.1 确定 BP 神经网络模型的权重和阈值 首先,在 MATLAB 中将第一步得到的预测数据中的三类事件作为输入层,相同年份的事件总数作为输出层,对训练数据进行归一化处理,并构建一个 BP 神经网络;配置网络参数并训练 BP 神经网络,归一化处理测试数据;然后利用训练好的模型进行预测;最后将预测结果反归一化处理并计算误差。

隐含层节点数目的确定是建立 BP 神经网络预测模型的关键,采用式 $n_1 = \sqrt{m+n} + a$ 计算节点数目。式中: n_1 为隐含层节点数目, m 为输入层节点数量, n 为输出层节点数目, a 为 1~10 的常数。

经计算确定隐含层节点数的取值范围为(3,12),并使用枚举法验证得出当节点数为 4 时,训练结果最佳。此时的误差结果如下:平均绝对误差 MAE 为 1.8309,均方根误差 RMSE 为 2.0067。所使用的输入层节点数目为 2,隐含层节点数目为 4,输出层节点数目为 1。BP 神经网络权重和阈值分别为

$$W_1 = \text{net. iw}\{1,1\}, W_2 = \text{net. lw}\{2,1\}; B_1 = \text{net. b}\{1\}, B_2 = \text{net. b}\{2\}。$$

生成的 BP 神经网络测试集预测值与实际值的对比如图 3 所示,此时的网络参数为最佳。

3.2.2 使用所定权重和阈值验证 2012—2016 年的数据误差 在保持所定权重和阈值的情况下,继续添加灰色模型预测出的 2012—2016 年的三类事件的数据,输出相应年份的神经网络模型预测的数据,并与原始数据做误差对比。此时,生成的 BP 神经网络预测值与实际值的平均绝对误差 MAE 为 0.986 12;均方根误差 RMSE 为 1.233 5。输出结果如图 4 所示,从输出的函数图像来看,精度较好。

3.2.3 使用 BP 神经网络进行预测所有灰色预测得到的数据 将通过灰色预测得到的跑道侵入、冲偏出跑道、跑道外接地三类事件的数据作为输入层,保持权重和阈值不变,使用 MATLAB 神经网络模型输出预测数据,此时 MATLAB 输出的数据即为使用 GM-BP 模型所得预测数据,并将组合预测数据与原始数据对比。预测结果与原始数据的对比情况如图 5 所示,可知使用 GM-BP 模型所得的预测结果与原始数据的拟合程度较高,预测精度较单一 GM(1,1)模型更好,验证了集成灰色预测与 BP 神经网络模型的方法在机场管制过程中的风险预测方面的可行性。




图 3 BP 神经网络测试集预测值与实际值对比




图 4 第二次输出的 BP 神经网络预测数据与原始数据对比




图 5 GM-BP 模型预测数据与原始数据对比

4 结论

针对机场管制过程中的风险研究,本文依据 SHELL 模型建立了管制系统风险运行指标体系,采用集

成 GM-BP 的方法,对冲偏出跑道、跑道侵入、跑道外接地三类事件,进行预测分析,并得到了预测精度较高的预测结果。得到如下结论:(1)本文所采用的 GM-BP 模型,可以改进灰色模型的预测数据,并在经过一定的网络参数配置后,使得预测结果的精度较高,在机场管制运行安全预警方面有着广泛的适用场景。(2)本文所采用的 GM-BP 模型,可以通过对 BP 神经网络的隐含层进行调整与训练,以适应不同类型的数据,相较于传统的灰色预测模型有着更强的适用性。

同时本文所提出的集成 GM-BP 的预测模型,可以对机场管制过程中的风险进行精度较好的预测,为风险管理的实施提供参考,也可推广到其他类型的安全事件,实现对事故数据的深入分析与利用,对科学管控民航不安全事件提供理论支持。

参考文献:

- [1] 中国民用航空局. 2023 年 6 月份主要生产指标统计[EB/OL]. (2023-07-20)[2024-01-02]. https://www.caac.gov.cn/XXGK/XXGK/TJSJ/202307/t20230720_220723.html.
- [2] WANG H Y, DONG Z Z, DENG T T, et al. En-route sector complexity control strategies in air traffic management[J]. Transactions of nanjing university of aeronautics and astronautics, 2021, 38(6): 901-913.
- [3] 张俊强,胡德振,曹悦琪,等. 基于信息熵的危险天气下终端区管制风险评估[J]. 南京航空航天大学学报, 2017, 49(S1): 125-130.
- [4] 张豫翔,王肖戎,吴明功,等. 基于模糊层次分析法和云模型的非常规情况下空管运行风险评估[J]. 安全与环境学报, 2016, 16(4): 42-47.
- [5] 李昂,聂党民,温祥西,等. 基于相依网络和 SVM 的管制系统运行态势评估[J]. 系统工程与电子技术, 2021, 43(5): 1287-1294.
- [6] 张兆宁,董环环. 基于突变理论的管制系统风险控制研究[J]. 安全与环境学报, 2021(2): 707-713.
- [7] 张兆宁,李文雅. 进近管制系统风险控制网络模型[J]. 中国安全科学学报, 2019, 29(2): 32-37.
- [8] 毛继志,吴欣蓬,吴磊,等. 基于文本挖掘的空管不正常事件风险预测研究[J]. 航空计算技术, 2020, 50(1): 1-8.
- [9] SU S Y, SUN Y C, ZENG Y N, et al. Aviation risk prediction based on Prophet-LSTM hybrid algorithm[J]. Aircraft engineering and aerospace technology, 2023, 95(7): 1054-1061.
- [10] KUMARI P, HAKUM S Z, KWON J S I, et al. An integrated risk prediction model for corrosion-induced pipeline incidents using artificial neural network and Bayesian analysis[J]. Process safety and environmental protection, 2022, 167: 34-44.
- [11] YU S X, WANG H. Risk forecasting in general aviation based on sparse de-noising auto-encoder neural network[J]. Systems engineering and electronics, 2019, 41(1): 112-117.
- [12] 李志超,姜宝良,潘登,等. 灰色理论在新乡百泉泉水流量动态分析中的应用[J]. 水文地质工程地质, 2023, 50(2): 34-43.
- [13] 高伟,李欣悦,张远,等. 长江流域生态系统服务价值时空演变与预测[J]. 生态学报, 2023, 43(15): 6203-6211.
- [14] 何金有,贾炜玮,张小勇,等. 应用 PROSAIL 模型对森林冠层叶面积指数遥感估测[J]. 东北林业大学学报, 2023, 51(11): 86-94.
- [15] 陈莺觉. 基于 SHEL 模型的地铁环境事故研究[J]. 产品可靠性报告, 2023(11): 111-113.
- [16] 廖勇,黄杰,方娜,等. 基于不确定性的机坪管制系统风险评估[J]. 现代计算机, 2024, 30(6): 73-79.

(下转第 131 页)