

中文引用格式:吴维,吴泽萱,王兴隆,等. 融合强化学习的DBN跑道侵入风险预测[J]. 中国安全科学学报,2024,34(7):20-27.

英文引用格式:WU Wei, WU Zexuan, WANG Xinglong, et al. Research on DBN incorporating reinforcement learning for runway intrusion risk prediction [J]. China Safety Science Journal,2024,34(7):20-27.

融合强化学习的DBN跑道侵入风险预测*

吴维¹讲师,吴泽萱²,王兴隆¹教授,祝龙飞²

(1 中国民航大学民航飞联网重点实验室,天津 300300;2 中国民航大学
空中交通管理学院,天津 300300)

中图分类号:X949

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2024.07.0229

资助项目:中央高校基本科研业务费项目中国民航大学专项(3122025098)。

【摘要】 为解决机场跑道侵入事件风险量化难度大、时效性差、精准性低等问题,提升跑道侵入风险预警能力,构建融合强化学习的动态贝叶斯网络(DBN)风险预测模型。首先,结合因果推断理论与灰色关联分析法分析跑道侵入历史事件,识别跑道侵入事件风险致因;其次,运用贝叶斯网络(BN)理论挖掘各风险因素间的关联性,并利用皮尔逊线性相关系数量化各因素间的关联关系,构建表征风险传播的致因关系网络;然后,利用三角模糊方法与隐马尔可夫模型(HMMs)优化DBN参数学习机制;最后,利用历史数据验证基于融合强化学习的DBN预测结果准确性。结果表明:基于融合强化学习的DBN预测结果与历史数据统计数值的拟合较好,准确率为84%,与单独DBN预测结果相比准确性提升10%;相比于采用度值评价法,通过互信息识别关键节点可有效提升预测准确率和区分度。

【关键词】 强化学习; 动态贝叶斯网络(DBN); 跑道侵入; 风险预测; 灰色关联分析

Research on DBN incorporating reinforcement learning for runway intrusion risk prediction

WU Wei¹, WU Zexuan², WANG Xinglong¹, ZHU Longfei²

(1 Key Laboratory of Internet of Aircraft, Civil Aviation University of China, Tianjin 300300, China;

2 College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In order to solve the problems of difficulty in quantifying the risk of airport runway incursion events, poor timeliness and low accuracy, and to enhance the capability of predicting runway incursion risks, a DBN model incorporating reinforcement learning for risk prediction was constructed. Firstly, causal inference theory was combined with grey relational analysis to analyze historical runway incursion events and identify the underlying risk factors. Secondly, Bayesian network (BN) theory was applied to explore the correlations among these factors and quantify these correlations using the Pearson linear correlation coefficient. This process helped in constructing a causation correlations network that effectively represented the propagation of risks associated with runway incursions. Then, the triangular fuzzy method and Hidden Markov Models (HMMs) were utilized to further refine and optimize the DBN parameter learning mechanism. Finally, the model's accuracy was validated using historical data. The results demonstrate that the proposed model's predictions of runway incursion risks closely align with the statistical

values of historical data, achieving an accuracy rate of 84%, which represents a significant 10% improvement over Bayesian network predictions. Additionally, the use of mutual information to identify key nodes is found to effectively improve accuracy and discrimination compared to the degree value evaluation method.

Keywords: reinforcement learning; dynamic Bayesian network (DBN); runway incursion; risk prediction; grey correlation analysis

0 引言

随着航空业的快速发展,多跑道机场面临的风险日益严峻,据美国联邦航空管理局^[1]与中国民航局网站^[2]公布数据显示,仅2008—2020年,涉及跑道侵入事件近5 600多件,跑道侵入已成为影响机场安全运行的关键事件之一。因此,厘清跑道侵入风险影响因素,识别风险传播过程并预测风险水平,对于预防此类事故发生,减少跑道侵入诱发的人员伤亡及经济损失,具有重要意义。

目前,国内外学者围绕跑道侵入等飞行区域不安全事件开展了大量研究。ROGERSON等^[3]统计分析跑道侵入事件原因,并将机场物理特征、运行特点和天气环境融入事件诱因范畴,拓展了跑道侵入致因分析的范畴。AJKM等^[4]通过计量经济学方法探究美国2002—2015年间跑道侵入事件诱因,识别不同场景下影响跑道侵入的关键性因素,明晰各因素间的关联关系。霍志勤等^[5-6]采用统计回归方法,分析跑道侵入影响因素及其相互作用关系,进而确定影响跑道侵入的关键致因,并据此厘清各因素间的因果关系;夏正洪等^[7]通过分析机场热点的时空特征,构建机场热点的风险评价模型,为分析机场跑道侵入风险等级提供了新思路;STROEVE等^[8]构建跑道侵入碰撞风险模型,量化分析了跑道侵入风险水平;王兴隆等^[9]利用复杂网络理论,构建了机场飞行区航空器冲突探测的栅格识别方法;罗军等^[10-11]构建了跑道侵入风险贝叶斯模型,结合模糊集和改进优劣解距离法计算贝叶斯模型参数,预测了跑道侵入发生的风险概率;黄宝军等^[12]针对跑道侵入多主体相互作用的过程,引入多智能体模型与时态逻辑交互语言构建了跑道侵入的仿真模型;焦卫东等^[13]提出了能够检测航空器跑道侵入风险的共形几何代数方法;王洁宁等^[14]系统分析了机场飞行区保障业务流程,并结合本体识别理论与贝叶斯理论分析跑道侵入事件风险水平;袁乐平等^[15]采用统计分析方法结合复杂网络,构建了跑道侵入致因网络模型;沈笑云等^[16]利用自动相关监视技术实时感知跑道侵

入风险态势,并建立了多级跑道侵入告警机制;吴维等^[17]基于风险识别方法构建跑道侵入风险传播模型,从网络脆弱性角度分析了风险推演过程。

综上,国内外专家系统研究了跑道侵入事件的风险要素,探析了各要素间的相互作用关系,并建立了多种跑道侵入风险评估模型。然而,由于跑道侵入事件的偶发性以及诱因复杂性,跑道侵入风险量化难度较大。为此,笔者拟基于融合强化学习的动态贝叶斯网络(Dynamic Bayesian Network, DBN),构建跑道侵入风险预测模型,以量化分析该类时间风险程度。

1 构建跑道侵入风险传播网络

跑道侵入事件通常是由于人员、设备、管理和运行环境某项发生变化导致的,而且,其中一项变化后会时序衍生其他风险事件,体现传播的时序特征。据此,可将历次跑道侵入的风险事件诱因设为节点,进而结合节点间的因果关系构建风险网络。

1.1 风险网络节点识别与确定

由于跑道侵入事件存在偶发性强、致因链长、隐藏性强等特点,仅采用统计历史数据无法精准识别诱因。为此,可通过采用因果推断与灰色关联分析相结合的方式识别诱因及其相互关系。

1) 识别风险致因链。根据美国联邦航空管理局^[1]和中国民航局网站^[2]公布的跑道侵入不安全事件数据,选取2008—2020年间典型的2 626件跑道侵入不安全事件为样本,分析样本数据。首先,提取分类不安全事件中涉及的要素,包括人员、设备、环境和管理等,并按照上述要素发生的时序特征,筛选出每次跑道侵入事件因果链条;其次,对因果链条的相似性进行聚类分析,构建典型因果链;最后,将典型的因果链条进行组合,形成因果链网,并利用因果推断理论分析验证链条的逻辑性和准确性。

从数据以及因果推断发现,跑道侵入致因事件中人的因素主要包括管制人员差错、飞行人员差错、场面保障人员、车辆驾驶员差错、工作年限高、反应时间长、陆空通话水平低、培训工作不到位、业务素

质差及不安全行为等事件;设备因素主要包括监视设备差错、通信设备差错和地面标志差错等事件;环境因素主要包括低能见度、地面湿滑、航班量大等事件;监管因素主要包括监管人员不足、规章制度不完善、监管频次低等事件。

2) 计算风险致因节点关联性。由于统计分析与因果推断形成的风险链条网络节点过于庞大,不利于风险快速精准识别,因此,需对风险链条网络进行优化。首先,基于灰色关联理论,计算致因间的关联系数;然后,对致因间的关联系数依次排序,分析关联度较低的因素对风险链条网络的影响程度,并对其进行优化;最后,形成核心跑道侵入风险传播网络,具体可表示为:

$$\sigma_{ck} = \frac{c_{\min} |\mu_{ck} - \mu_{c0}| + \rho c_{\max} |\mu_{ck} - \mu_{c0}|}{|\mu_{ck} - \mu_{c0}| + \rho c_{\max} |\mu_{ck} - \mu_{c0}|},$$
$$c = 1, 2, \dots, m; k = 1, 2, \dots, n \quad (1)$$

$$r_k = \frac{\sum_{c=1}^m \sigma_{ck}}{m}, c = 1, 2, \dots, m; k = 1, 2, \dots, n \quad (2)$$

式中: σ_{ck} 为灰色关联系数; c 为跑道侵入致因的种类; k 为同一致因种类中的评价指标类别; μ_{ck} 为致因种类 c 对应评价指标 k 的值; μ_{c0} 为同一致因种类下评价指标的参考值; c_{\min} 为同一致因种类下评价指标的最小值; c_{\max} 为同一致因种类下评价指标的最大值; ρ 为削弱最大最小化极差导致关联系数失真而引入分辨系数,取 $\rho = 0.5^{[15]}$; m 为跑道侵入致因分类总数; r_k 为灰色关联度。

以运行环境因素为例,计算出的致因灰色关联度为: $r_k = (0.73, 0.74, 0.82, 0.63, 0.21, 0.71, 0.58, 0.23, 0.43)$, 从大到小依次为: 跑滑布局复杂、航班量过大、低能见度、地面湿滑、夜间、降水、沙尘、低温、高原机场, 其中低温与高原机场作为环境致因对跑道侵入关联性最小。因此,删除上述 2 种因素,并保留关联度高的致因构建风险传播网络。采用上述方法,优化已有因果链条,最终确定涵盖人员、设备、环境和管理 4 个类别的 61 个致因节点,见表 1。

表 1 致因节点

Table 1 List of causal nodes

符号	名称	符号	名称	符号	名称
a_1	人的因素	a_{22}	管制人员培训工作不到位	b_7	降水
a_2	场面保障人员和车辆驾驶员差错	a_{23}	管制人员工作年限低	b_8	沙尘
a_3	管制人员差错	a_{24}	管制人员工作强度高	c_1	设备因素
a_4	飞行人员因素	a_{25}	管制人员人数少	c_2	监视设备故障
a_5	场面人员未及时发现危险	a_{26}	复诵错误	c_3	通信设备故障
a_6	场面人员未经许可进入跑道	a_{27}	飞行人员对机场不熟悉	c_4	地面标志有误
a_7	进入错误跑道	a_{28}	飞行人员未听指令进入跑道	c_5	场面灯光中断
a_8	场面人员和车辆驾驶员反应迟钝	a_{29}	飞行人员处置不及时	c_6	场面灯光故障
a_9	场面人员和车辆驾驶员业务素质差	a_{30}	飞行人员未及时发现错误	c_7	设备可靠性差
a_{10}	场面人员和车辆驾驶员对机场熟悉程度低	a_{31}	飞行人员陆空通话水平低	c_8	通信中断
a_{11}	场面人员和车辆驾驶员工作经验低	a_{32}	飞行人员反应时间长	c_9	标志模糊不清或不合理
a_{12}	场面人员和车辆驾驶员工作年限	a_{33}	飞行人员业务素质差	c_{10}	设备质量差
a_{13}	场面人员和车辆驾驶员培训工作不到位	a_{34}	飞行人员工作年限低	c_{11}	检修频率低
a_{14}	未发现飞行人员复诵错误并纠正	a_{35}	飞行员经验少	d_1	监管因素
a_{15}	未发现飞行人员、车辆等异常并及时处置	a_{36}	飞行人员培训不到位	d_2	监管频次低
a_{16}	管制员未按规定操作	b_1	环境因素	d_3	规章执行率低
a_{17}	管制指令不及时	b_2	地面湿滑	d_4	监控手段不足
a_{18}	管制人员陆空通话水平低	b_3	低能见度	d_5	监管人员不足
a_{19}	管制人员业务素质差	b_4	航班流量大	d_6	监管投入不足
a_{20}	管制人员工作经验不足	b_5	跑滑布局复杂		
a_{21}	管制人员反应时间长	b_6	夜间		

1.2 基于 BN 计算节点风险值

统计历史数据发现,由于跑道侵入偶发性因果链条中致因间的风险作用机制存在一定的因果关系不确定性^[15]。为此,基于历史数据并利用 BN 挖掘

各致因间的作用过程和风险传播程度,并据此进一步构建风险传播因果链序网络。以管制指令不及时风险值 $F_g(a_{17})$ 为例,使用 BN 计算关联致因对其所属分类形成风险的贡献度,根据事件分析致因节点间

关联关系确定概率 $p(a_{17})$ 需要先计算出 $p(a_{19})$ 、 $p(a_{20})$ 、 $p(a_{21})$ 、 $p(a_{22})$ 、 $p(a_{24})$ 、 $p(b_4)$ 。其中, $p(a_{17})$ 与 a_{21} 相关, 根据管制单位对人员素质的分类规则将 a_{21} 分高、中、低 3 档, 分别为 30、20 和 10 s, 所对应 $p(a_{21})$ 分别为 0.05、0.3、0.6; $p(a_{24})$ 与 b_4 相关, 根据实际运行情况将 b_4 分为高、中、低 3 档, 所对应 $p(b_4)$ 分别为 0.05、0.15、0.2; $p(a_{19})$ 与 a_{22} 有关, 将 $p(a_{22})$ 分为高、低 2 档, 所对应 $p(a_{22})$ 分别为 0.1、0.3。按照初始的状态不同, 有 18 种概率计算组合。因此, 需要计算出 18 种组合对应的 $p(a_{17})$, 具体如下:

$$F_g(a_{17}) = \sum_{\bar{k}=1}^n \theta_k^g P(a_{17}/A_k^g) \quad (3)$$

$$\theta_k^g = \frac{1\ 000\bar{k}_A + 100\bar{k}_B + 10\bar{k}_C + \bar{k}_D}{\bar{k}_A + \bar{k}_B + \bar{k}_C + \bar{k}_D} \quad (4)$$

式中: $F_g(a_{17})$ 为致因 a_{17} 在第 g 种条件下的风险值; $g = 1, 2, \dots, 18$ 为 18 种不同条件概率的组合; P 为条件概率; A_k^g 为导致 a_{17} 发生第 g 种条件下的前序致因集合; \bar{k} 为前序致因节点对应的事件编号; θ_k^g 为第 g 种组合下第 \bar{k} 节点事件发生所导致 a_{17} 发生的风险值; 将前序致因节点导致 a_{17} 发生概率分为 A、B、C、D 等 4 个等级, A 为最高影响等级, D 为最低影响等级; \bar{k}_A 、 \bar{k}_B 、 \bar{k}_C 、 \bar{k}_D 为 \bar{k} 节点发生导致 a_{17} 分属 A、B、C、D 不同等级的对应次数, 将不同前序致因节点导致该节点发生的概率转变为风险值。

根据上述公式计算 $F_g(a_{17})$ 风险值, 见表 2。同理, 可算出其他节点的风险值。

表 2 a_{17} 对应的 18 种风险值

Table 2 Eighteen risk values corresponding to a_{17}

风险	F_1	F_2	F_3	F_4	F_5	F_6
取值	28.6	28.3	27.7	27.6	27.3	26.7
风险	F_7	F_8	F_9	F_{10}	F_{11}	F_{12}
取值	24.7	24.4	23.8	23.9	23.5	22.9
风险	F_{13}	F_{14}	F_{15}	F_{16}	F_{17}	F_{18}
取值	29.7	29.5	28.9	25.7	25.4	24.9

1.3 基于时序特征优化风险网络

由于跑道侵入事件通常是由因多种风险叠加耦合形成, 同时, 跑道侵入事件往往是具有时序关系的动态风险传播特性, 因此需要综合考虑因素的时序关系。为进一步剖析跑道侵入事件中节点的耦合关系, 需要将跑道侵入事件因果链中节点被触发的时间顺序进行划分, 进而得到跑道侵入事件的时序数据, 并采用皮尔逊线性相关系数优化跑道侵入的致

因网络, 计算节点在不同事件下不同时段的风险变化相关性, 最终得出表征节点风险时序关系的皮尔逊相关系数, 具体如下:

$$\bar{\omega}_{ij} = \frac{\sum_{\hat{n}=1}^{\hat{N}} \sum_{t=1}^T |(\hat{F}_{\hat{n}}^i(i) - \bar{F}^i(i))| \cdot |(\hat{F}_{\hat{n}}^i(j) - \bar{F}^i(j))|}{\sqrt{\sum_{\hat{n}=1}^{\hat{N}} \sum_{t=1}^T (\hat{F}_{\hat{n}}^i(i) - \bar{F}^i(i))^2 \sum_{\hat{n}=1}^{\hat{N}} \sum_{t=1}^T (\hat{F}_{\hat{n}}^i(j) - \bar{F}^i(j))^2}} \quad (5)$$

式中: $\bar{\omega}_{ij}$ 为节点 i 与节点 j 的皮尔逊线性相关系数值, 当 $\bar{\omega}_{ij} \geq \phi$ 时, 节点 i 与节点 j 具有连边, ϕ 为设定的阈值; \hat{n} 为某个跑道侵入事件, \hat{N} 为跑道侵入事件总数; $\hat{F}_{\hat{n}}^i(i)$ 为节点 i 在第 \hat{n} 个事件中 t 时刻的风险值, $\bar{F}^i(i)$ 为节点 i 在 t 时刻所有事件中的平均风险值; $\hat{F}_{\hat{n}}^i(j)$ 为节点 j 在第 \hat{n} 个事件中 t 时刻的风险值; $\bar{F}^i(j)$ 为节点 j 在 t 时刻所有事件中的平均风险值。

2 确定跑道侵入 DBN 参数

2.1 先验概率的计算与优化

由于监管因素存在历史数据不足、关联程度不够明晰的问题, 故结合专家经验与业务知识对根节点的先验概率进行修正和完善。为消除不同专家认识偏差和主观性, 采用模糊综合评价方法计算根节点的先验概率。模糊综合评价方法主要步骤如下:

步骤 1: 确定评价对象根节点种类以及在实际运行中所处的概率水平。

步骤 2: 依据跟节点种类, 收集专家意见。设定 5 个不同等级的评价结果, 即 $L = \{1, 2, \dots, 5\}$, 分别表示发生概率极低、低、一般、高、很高。

步骤 3: 建立模糊逻辑规则。为便于专家进行客观、科学评价, 构建隶属度函数, 见表 3。

表 3 隶属度函数

Table 3 Membership functions

节点状态	概率范围	模糊数集
极低	0.1	(0.1, 0.1, 0.2)
低	0.3	(0.2, 0.3, 0.4)
一般	0.5	(0.4, 0.5, 0.6)
高	0.7	(0.6, 0.7, 0.8)
极高	0.9	(0.8, 0.9, 0.9)

步骤 4: 建立逻辑规则处理专家意见。利用权

重化运算规则处理专家意见,获取专家对不同根节点意见集,具体如下:

$$M = \frac{\sum_{e=1}^E \eta^e \cdot M^e}{\sum_{e=1}^E \eta^e} = (M_{ij}^1, M_{ij}^2, M_{ij}^3) \quad (6)$$

式中: M 为专家意见先验概率的综合模糊数; M^e 为第 e 个专家对各个节点先验概率的模糊数; E 为专家总数; M_{ij}^l 为集成专家意见在不同隶属度下的模糊数均值; η^e 为 e 专家意见对应权重。

步骤5:解模糊化。利用期望值规则将模糊数均值转变为先验概率值,具体如下:

$$P_{cl}^\sigma = \varepsilon^1 M_{ij}^1 + \varepsilon^2 M_{ij}^2 + \varepsilon^3 M_{ij}^3 \quad (7)$$

式中: P_{cl} 为解模糊化的概率值; ε 为对应解模糊数均值的权重; σ 为对节点所处的状态水平,共分为5个状态水平。

步骤6:综合评价。将解模糊化的概率值进行归一化处理,得到根节点概率值,具体如下:

$$\hat{P}_g = \frac{P_{cl}}{\sum_{\sigma=1}^5 P_{cl}^\sigma} \quad (8)$$

式中 \hat{P}_g 为综合处理的根节点概率值。

2.2 基于强化学习的条件概率计算

DBN 参数学习通常在给定事件因果关系的基础上,从训练数据中学习,进而计算节点间条件概率和转移概率。现有方法中主要采用专家评价、半定量分析等方式,但也存在难以通过上述方式确定其条件概率的情况,如 a_{29} 、 a_{30} 、 a_{35} 等节点,这使得在 DBN 参数计算时存在准确性不高、颗粒度不足和时序特征不强等问题。由于隐马尔可夫模型(Hidden Markov Models, HMMs)具有较强学习能力,可有效分析隐含的随机过程,为此,采用 HMMs^[18] 计算 DBN 模型参数。根据 2.1 和 2.2 参数学习确定 DBN 参数,利用 DBN 专业软件 GeNIe 构建相应动态风险传播网络,根据收集到的信息完成动态参数学习,并对网络进行更新,进而实现风险传播概率的精准推算。

3 跑道侵入风险预测实例分析

3.1 构建跑道侵入风险传播的 DBN

基于 1.2 与 1.3 节进一步构建跑道侵入的 DBN 结构,如图 1 所示。该图将统计的跑道侵入事故以及事故症候涉及的风险因素分为 4 个类别 61 个节点,连边呈现节点间的因果链序关系。

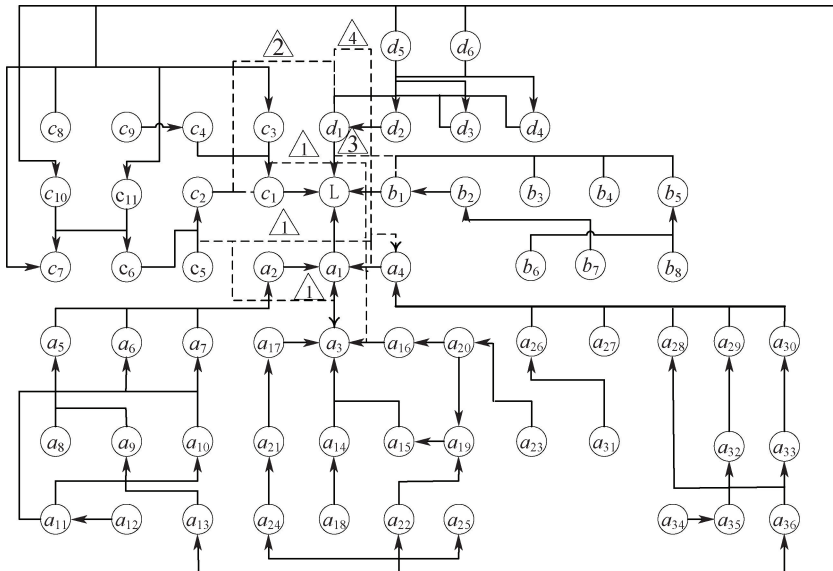


图 1 跑道侵入风险传播 DBN

Fig. 1 DBN of runway incursion risk propagation

3.2 数据收集与处理

选取 2008—2020 年间 2 626 件跑道侵入不安全事件数据作为样本^[1-2],并选取 2008—2013 年的 1 608 个事件作为参数学习样本,分别采用 BN、DBN 和 HMMs 学习 DBN,预测 2014—2020 年发生的

1 018 起跑道侵入事件风险。

3.3 融合强化学习方法的风险预测结果分析

针对致因节点的相同变化,分别采用 3 种方法对跑道侵入事件的发生概率进行预测,根据专家意见和实际运行经验将风险概率高于 0.85 视为高风

险,即会发生侵入事件如实际发生侵入事件认为预测准确,其余为中低风险,即可能发生如实际发生侵入事件认为预测不准确。

采用 DBN,以年为单位将 2014—2020 年间的跑道侵入数据划分为 7 个时间片,由于获取的跑道侵入历史事件数据是文本数据,将文本数据转化为跑道侵

入致因链的 61 个节点的离散化数据(节点风险程度),预测跑道侵入风险程度。DBN 是在 BN 基础上引入时间变量,通过历史数据表达节点间推理关系,对将来趋势进行预测,根据图 1 的风险传播网络图和历史数据,预测目标时间片的跑道侵入风险,将发生、不发生分别记为 True、False,预测过程如图 2 所示。

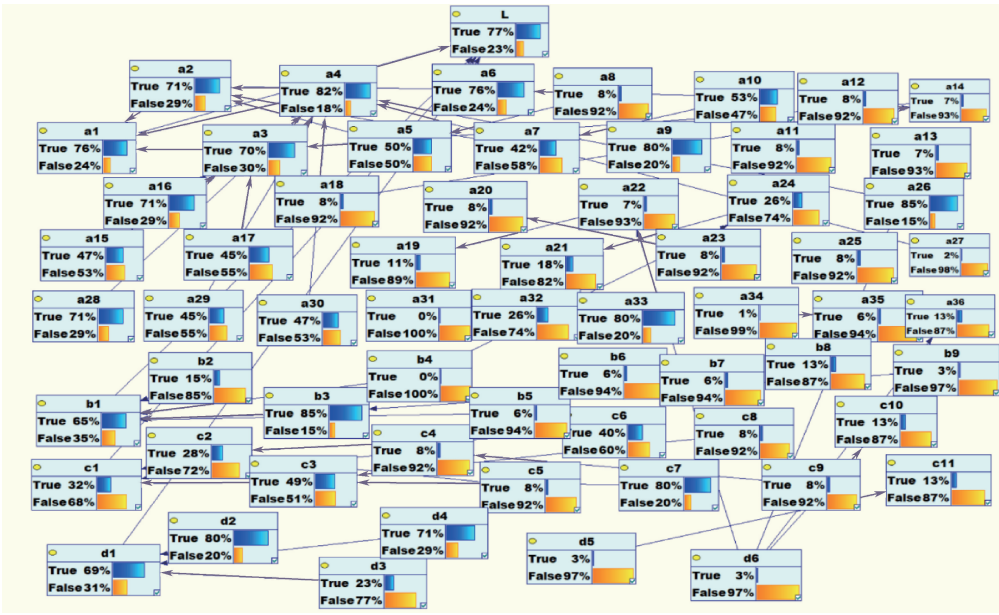


图 2 DBN 跑道侵入风险预测

Fig. 2 DBN runway incursion risk prediction

利用 HMMs 参数学习 DBN 进行预测时,首先按照历史数据时序关系,并采用模糊综合评价与 HMMs 计算先验概率和条件概率,最后更新 DBN 参数以预测结果。采用 3 种方法预测 2014—2020 年跑道侵入事件发生情况,上述 3 种方法预测准确率如图 3 所示。

DBN 和 BN 预测模型精度分别提升 4 % 和 10 %,而且具有良好的预测稳定性,其预测偏离程度及波动程度最小,说明该方法在强时序关系风险事件预测中具有较强的稳定性,见表 4。

表 4 不同风险预测方法的结果

Table 4 Distribution of risk prediction results using different methods

预测结果 概率值	预测结果占比分布情况/%		
	BN	DBN	HMMs 学习的 DBN
[0, 0.5)	6.4	5.5	2.0
[0.5, 0.85]	19.2	14.2	13.8
(0.85, 1]	74.4	80.3	84.2

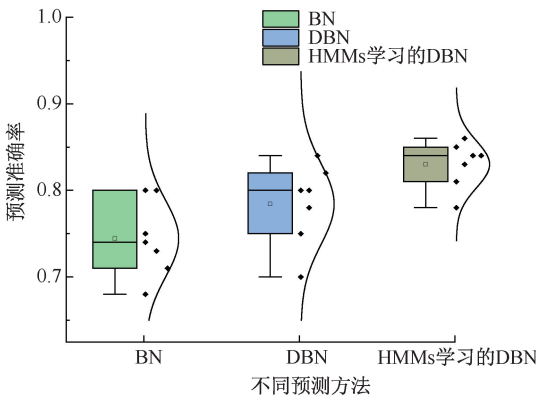


图 3 不同风险预测方法预测结果对比

Fig. 3 Comparison of risk prediction results using different methods

上述 3 种方法预测准确率的中位数分别为 0.74, 0.80 和 0.84, 采取 HMMs 强化学习 DBN 比

3.4 灵敏度分析

为分析跑道侵入网络中观测节点(根节点)对风险预测结果的影响情况,以及不同时序条件下风险节点与风险预测结果相关程度,对节点进行灵敏度分析。首先采用先验知识法,分析观测节点对风险预测灵敏度,随后通过调整观测节点的风险发生概率计算跑道侵入事件的风险变化情况,计算结果如图 4 所示。

由图 4 可知:多数观测节点风险增加并未使得




图4 观测节点灵敏度分析

Fig. 4 Sensitivity analysis of observation nodes

跑道侵入风险显著波动,整体与跑道侵入风险呈正向关系,跑道侵入风险概率变化在30%以内。

为确定不同时序条件下,节点间敏感度变化情况,采用互信息法对网络中节点进行灵敏度分析。互信息是衡量随机变量之间相互依赖程度的度量,可挖掘节点间关联关系^[19]。采用互信息法表征2个节点间相互关系、信息共享程度以及风险波动对彼此的影响情况,计算式为:

$$I(i;j) = \sum_i \sum_j p(i,j) \log_2 \left(\frac{p(i,j)}{p(i)p(j)} \right) \quad (9)$$

式中: $I(i;j)$ 为两个节点间互信息; $p(i,j)$ 为节点 i,j 联合概率; $p(i)$ 与 $p(j)$ 为对应节点的边缘概率。

由于网络节点数量较多,仅展示互信息前7位的节点随时间步长下互信息值的变化情况,如图5所示。




图5 不同时间片下互信息变化曲线

Fig. 5 Change curve of mutual information at different time slots

由图5可知:网络节点的互信息值随时间步长增加并没有发生明显变化,其波动范围在13%以内。

3.5 关键节点识别

识别风险网络关键节点是制定有效控制策略的基础,传统复杂网络主要采用度值评价节点重要性,而这种方法会造成评价客观性低。为此,提出采用互信息作为识别风险网络关键节点的方法,该方法通过对比复杂网络中节点度值、互信息值与历史事件中节点致灾性,得出互信息值表征历史事件中节点致灾性准确程度更高。然而,度值、互信息值和历史事件发生次数占比量纲不一致。为此,对互信息值扩大1000倍,对历史事件发生次数占比扩大100倍,由于图幅限制按照度值排序取17个节点,在不同方法下的对比情况如图6所示。




图6 不同方法识别关键点对比情况

Fig. 6 Comparison of different methods for key point identification

相比于度值识别风险网络关键节点,互信息法可以提升识别准确率,并增强不同节点重要程度的分辨能力。

4 结论

1) 融合灰色关联理论与BN等强化学习方法,有助于降低跑道侵入偶发性强对致因网络构建的干扰,厘清跑道侵入致因间关联关系,增强致因网络构建的精准性。

2) 采用三角模糊方法与HMMs算法优化DBN参数学习,有效利用时变信息,使跑道侵入风险的预测准确率相比于传统方法提升10%,达到84%。

3) 引入互信息方法分析节点间灵敏度,相比与传统复杂网络度评价方法,其识别风险网络中关键节点的准确率显著提升。

参 考 文 献

- [1] United States Department of Transportation of Federal Aviation Administration. Runway safety statistics[R], 2022.
- [2] 中国民用航空局航空安全办公室. 中国民航航空安全报告[R], 2021.
- [3] ROGERSON E C, LAMBERT J H. Prioritizing risks via several expert perspectives with application to runway safety[J]. Reliability Engineering and System Safety, 2012, 103(3):22-34.
- [4] JIJOK M, WESLEY L B, MAJOR B, et al. Statistical modelling of runway incursion occurrences in the United States - science direct[J]. Journal of Air Transport Management, 2017, 65(6):54-62.
- [5] 霍志勤, 韩松臣. 跑道侵入的威胁与差错分析及控制研究[J]. 安全与环境学报, 2012, 12(4):192-196.
HUO Zhiqin, HAN Songchen. Analysis on the threats and errors caused by the runway incursions and the corresponding controlling ways[J]. Journal of Safety and Environment, 2012, 12(4):192-196.
- [6] 霍志勤, 韩松臣. 基于案例推理和规则推理融合的跑道侵入事件调查[J]. 中国安全科学学报, 2012, 22(7):53-58.
HUO Zhiqin, HAN Songchen. Runway incursions investigation based on integration of rule-based reasoning and case-based reasoning[J]. China Safety Science Journal, 2012, 22(7):53-58.
- [7] 夏正洪, 万健, 朱新平. 机场热点时空分布特征及运行风险评价[J]. 中国安全科学学报, 2018, 28(1):93-98.
XIA Zhenghong, WAN Jian, ZHU Xinping. Research on spatial and temporal distribution characteristics of airport hotspots and airport operational risk assessment [J]. China Safety Science Journal, 2018, 28(1):93-98.
- [8] STROEVE S H, SOM P, DOORN B A V, et al. Strengthening air traffic safety management by moving from outcome-based towards risk-based evaluation of runway incursions[J]. Reliability Engineering & System Safety, 2016, 147(8):93-108.
- [9] 王兴隆, 周督异. 基于复杂网络的飞行区冲突关键栅格区识别[J]. 中国安全生产科学技术, 2023, 19(8):32-38.
WANG Xinglong, ZHOU Duiyi. Identification of critical grid areas in flight area conflicts based on complex network [J]. Journal of Safety Science and Technology, 2023, 19(8):32-38.
- [10] 罗军, 林雪宁. 基于模糊集和改进 TOPSIS 方法的跑道侵入风险评估[J]. 中国安全科学学报, 2012, 22(12):116-121.
LUO Jun, LIN Xuening. Runway incursion risk assessment based on fuzzy sets theory and improved TOPSIS method[J]. China Safety Science Journal, 2012, 22(12):116-121.
- [11] 罗军, 林雪宁, 闫永刚. 基于高斯贝叶斯网络模型的跑道侵入影响因素研究[J]. 安全与环境学报, 2012, 12(3):196-199.
LUO Jun, LIN Xuening, YAN Yonggang. Analysis of runway incursion influence factors based on gaussian bayesian network model [J]. Journal of Safety and Environment, 2012, 12(3):196-199.
- [12] 黄宝军, 房晓丹, 王洁宁. 基于多 agent 的跑道侵入风险分析建模及仿真[J]. 系统仿真学报, 2017, 29(4):910-917, 925.
HUANG Baojun, FANG Xiaodan, WANG Jiening. Risk simulation analysis of runway incursions based on multi agents [J]. Journal of System Simulation, 2017, 29(4):910-917, 925.
- [13] 焦卫东, 王瑞冬, 姚军强, 等. 跑道侵入与冲突检测的共形几何代数描述[J]. 航空学报, 2022, 43(5):483-492.
JIAO Weidong, WANG Ruidong, YAO Junqiang, et al. Conformal geometric algebraic description of runway incursion and conflict detection [J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(5):483-492.
- [14] 王洁宁, 庾睿. 集成本体和 BN 的跑道侵入态势评估方法[J]. 计算机应用研究, 2019, 36(12):3773-3776.
WANG Jiening, YU Rui. Situation assessment method of runway incursion based on combination of ontology and BN[J]. Application Research of Computers, 2019, 36(12):3773-3776.
- [15] 袁乐平, 赵力梵, 张文东, 等. 基于复杂网络的民航跑道侵入事件分析[J]. 安全与环境学报, 2023, 23(5):1368-1375.
YUAN Leping, ZHAO Lifan, ZHANG Wendong, et al. Analysis of civil aviation runway incursion incident based on complex network [J]. Journal of Safety and Environment, 2023, 23(5):1368-1375.
- [16] 沈笑云, 张肖艳, 张思远. 基于 ADS-B 的跑道侵入冲突检测与告警研究[J]. 中国安全科学学报, 2019, 29(9):119-124.
SHEN Xiaoyun, ZHANG Xiaoyan, ZHANG Siyuan. Research on runway incursion conflict detection and alarm based on ADS-B [J]. China Safety Science Journal, 2019, 29(9):119-124.
- [17] 吴维, 罗欣然, 魏明. 基于 SD 模型的跑道侵入风控网络脆弱性分析[J]. 中国安全科学学报, 2021, 31(4):41-48.
WU Wei, LUO Xinran, WEI Ming. Vulnerability assessment of runway intrusion risk control network based on SD model [J]. China Safety Science Journal, 2021, 31(4):41-48.
- [18] STAMP M. A revealing introduction to hidden markov models[J]. Lee Assp Magruine, 2004, 8(5):1-21.
- [19] 乌兰, 刘全, 黄志刚, 等. 优势加权互信息最大化的最大熵分层强化学习[J]. 计算机学报, 2023, 46(10):2066-2083.
WU Lan, LIU Quan, HUANG Zhigang, et al. Maximum entropy hierarchical reinforcement learning with advantage-weighted mutual information maximization[J]. Chinese Journal of Computers, 2023, 46(10):2066-2083.

作者简介: 吴维 (1982—), 男, 河北承德人, 硕士, 讲师, 主要从事空中交通系统优化与管理方面的研究。
E-mail: wuweir2029@163.com.