

动态预测技术在航班运行风险中的应用

王岩韬[†], 刘宏, 唐建勋, 赵焱飞

(中国民航大学天津市空管运行规划与安全管控重点实验室, 天津 300300)

摘要: 为了解决静态评估技术无法适应航班运行风险要素频繁动态变化的问题, 通过对中国民航近10年5000余项不安全事件的系统分析, 识别风险关键指标, 构建以航班运行过程为对象的动态贝叶斯网络, 并根据统计结果初始化网络参数; 通过对真实航班仿真计算, 使用原有风控系统中的航行情报、气象预报等数据对参数实时修正, 得到对飞行全程风险的预测结果. 结果表明: 航班在起飞前和巡航过程中, 安全度高; 在进近和着陆阶段, 受机场风切变的影响, 风险值剧烈变化, 低风险概率降低到17.2%, 中等风险升至70.9%, 表明安全着陆可能性低, 建议措施为返航或备降, 该策略与实际运行结果一致, 说明预测方案可行有效. 进而, 从单一案例扩大至2017年雷雨和冰雪季规模性数据验算, 验证预测结果与实际运行状况吻合率达到80.4%, 进一步证实了所提方案的可靠性.

关键词: 航空运输; 航班运行风险; 动态预测; 动态贝叶斯网络(DBN); 网络参数; 航班运行风控系统

中图分类号: N945.24; U8; V355.2

文献标志码: A

Dynamic prediction technology in the application of flight operation risk

WANG Yan-tao[†], LIU Hong, TANG Jian-xun, ZHAO Yi-fei

(Tianjin Key Laboratory of ATM Operation Planning and Safety Management, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In order to solve the problem that the static assessment technology can not be corrected timely and effectively according to the dynamic changes of flight operation risk factors, through the statistics and analysis of over 5000 civil aviation unsafe incidents in the past decade, the dynamic Bayesian network is established for flight operation risk by identifying key risk indicators, and the dynamic Bayesian network parameters are initialized according to the statistic results. Then, a real flight example is simulated and the network parameters are corrected in real time according to the information of the navigation system, and weather forecast data in the risk control system, thus the prediction results of pre-flight and in-flight are obtained. The results show that flight safety level is high in the process of departure and cruise, the risk of landing is significantly fluctuating under the influence of the wind shear of the Airport, and the risk of low risk possibility is reduced to 17.2% and the medium risk is up to 70.9%, which shows that alternate or flight return is recommended for low safe landing likelihood. The strategy is consistent with the actual operation results, which shows that the scheme is feasible and effective. In order to confirm further, the operation data expands to thunderstorm and snow season in 2017 from a single case, the verification results show that the forecasting program is 80.4% consistent with the actual operations, indicating that the forecasting scheme is reliable.

Keywords: air transportation; flight operation risk; dynamic predict; dynamic Bayesian network(DBN); network parameters; flight operation risk control system

0 引言

航班运行是一个连续的动态过程, 其影响因素种类、形式、数目繁多, 运行风险随条件不断改变. 面对此类复杂系统, 构建科学的评估和预测方法是提高安全水平的必要措施. 欧美民航的安全管理和风险定量评估研究在2000年后已有成果和产品^[1-3]. 国内

民航安全类的研究热点最早集中于飞行和空管, 自孙瑞山等^[4]将风险管理引入航空公司运行领域后, 王岩韬等^[5]协助民航局建立了通用性、示范性的航班运行风险评估体系. 在此基础上, 民航局在2015年制定和发布了《航空承运人运行控制风险管控系统实施指南》, 以海南航空为代表的52家国内运输航空公司相

收稿日期: 2018-01-20; 修回日期: 2018-07-21.

基金项目: 国家重点研发计划项目(2016YFB0502400); 国家自然科学基金项目(71701202, U1433111); 民航局科技项目(20150204); 空管基地开放基金项目(KGJD201601).

责任编辑: 张维海.

[†]通讯作者. E-mail: CAUCwyt@126.com.

继开发了航班运行风险管控系统. 在风险评价方法研究中, 各位学者先后尝试了隶属函数、风险矩阵、三角模糊数、贝叶斯置信网络、决策试验与实验室法、熵权与综合评价法、灰色理论、不确定理论以及混合模型等各类风险评估技术^[5-8], 但上述方法存在一个共有缺点——依赖专家评分, 而在面对海量评分项时专家判断存在局部失控现象. 而后, 在机器学习方法探索中, 王岩韬等首先运用可拓评价解决了精确赋值困难的问题^[6], 然后在厦门航空示范应用了神经网络和支持向量机等机器学习算法^[7], 并在历史统计数据的基础上, 使用贝叶斯反向推理, 在中国国际航空公司、中国南方航空公司建立了关键风险推断模型^[8]. 对于民航非动态问题, 上述系列研究已取得了较好成果, 但是若将研究对象从静态航班扩展为动态运行航班, 上述评估技术便无法适应航班要素频繁快速变化的特点, 缺少结果反馈, 无法及时修正, 致使评估准确性偏低, 滞后性明显. 动态预测技术相比公路等行业有明显差距^[9], 是民航安全领域尚未有效解决的关键问题之一.

利用图模型和概率论的贝叶斯网络是解决复杂因果关系问题的有效工具. Pearl^[10]提出了贝叶斯网络构想; Dean等^[11]通过扩展马尔可夫模型提出了动态贝叶斯的概念; Heckerman^[12]系统阐述了网络应用技术; Nodelman等^[13]提出了连续动态贝叶斯网络, 用以描述连续时间上的概率分布, 在引入非稳态时间序列后, 非同构动态贝叶斯网络被构建出, 用于不同经济周期的金融市场分析问题研究^[14]. 如今, 动态贝叶斯网络已广泛应用于处理故障诊断、态势评估等, 研究热点包括结构学习、参数学习及网络推理等^[15].

针对前续研究中风险网络结构大多基于经验, 参数学习依赖专家判断的问题, 本文通过对民航近10年间不安全事件进行统计, 分析风险因素, 识别关键指标, 依照统计结果初始化动态网络参数, 构建基于数据的航班运行风险动态预测模型. 在仿真验证阶段, 从单一航班案例扩大至规模性数据校验, 证明预测方案兼具有效性和可靠性. 对于国内民航安全管理工作, 首次使用动态贝叶斯网络分析方法, 构建的基于行业数据的风险网络具备广泛适用性; 对于目前行业亟需解决的全程监控和事前管控问题, 提出的航班风险实时评估和预测方案具有实用价值.

1 动态贝叶斯网络

1.1 动态贝叶斯网络概述

静态贝叶斯网络(SBN)主要由有向无环图与条件概率表构成. 在有向无环图中, 节点代表随机变

量, 通过边表示变量之间的概率依赖关系. 例如, 一条边由节点A到B, 则称A是B的父节点, B是A的子节点, $P(A|B)$ 则表示A与B之间的条件概率关系. 条件概率可用 $P(x_i/\text{parent}(x_i))$ 表示, $\text{parent}(x_i)$ 是节点 x_i 的父节点. 贝叶斯拓扑结构中节点集 $\{x_1, x_2, \dots, x_n\}$ 的概率分布可用下式表示:

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i/\text{parent}(x_i)). \quad (1)$$

动态贝叶斯网络(DBN)是SBN的扩展, 是表示复杂随机过程的有向图模型. 用 X^t 表示节点变量在 t 时刻的状态. 首先, 假设其随机过程满足马尔科夫假设, 表示为 $P(x^t/(x^0, \dots, x^{t-1})) = P(x^t/x^{t-1})$; 然后, 假设随机过程是稳定的, 对于所有的时间 t , 条件概率 $P(x^t/x^{t-1})$ 始终相同; 最后, 假设相邻时刻条件概率过程是平稳的, 即 $P(x^t/x^{t-1})$ 与时间 t 无关^[16-17].

定义转移网络中 B_{\rightarrow} 为贝叶斯片段, 节点包括 $x^t \cup x^{t+1}$. x^t 表示当前状态, 没有父节点; x^{t+1} 表示下一时刻状态, 具有条件概率 $P(x^{t+1}/\text{parent}(x^{t+1}))$. 转移网络 B_{\rightarrow} 的条件概率分布^[18]为

$$P(x^{t+1}/x^t) = \prod_{i=1}^n P(x_i^{t+1}/\text{parent}(x_i^{t+1})). \quad (2)$$

一个DBN可表示为二元组 (B_0, B_{\rightarrow}) , B_0 是以 x^0 为节点的初始网络, B_{\rightarrow} 是转移网络. 对于任意时刻 t , x^t 的联合概率分布^[18]如下:

$$P(x^0, \dots, x^t) = P(x^0) \prod_{i=1}^n P(x^t/x^{t-1}). \quad (3)$$

构建DBN时, 首先提取研究对象的相关变量, 确定状态值; 然后根据变量间依赖关系, 建立拓扑结构图; 最后依据变量间依赖关系强弱, 建立条件概率表.

1.2 动态贝叶斯网络推理

在隐节点推理中, 无论是静态贝叶斯网络还是动态贝叶斯网络, 贝叶斯公式都是推理的基础. 本文第3节案例中的网络节点包括: 观测节点 y_1, y_2, \dots, y_{20} , 可通过观测得到; 隐节点 x, x_1, \dots, x_4 , 需经过推理得到, 节点含义参见图1.

先验网络模型推理如下所示:

$$P\left(\frac{x, x_1, \dots, x_4}{y_1, y_2, \dots, y_{20}}\right) = \frac{\prod_j^{20} P(y_j/\text{parent}(y_j)) \prod_i^5 P(x_i/\text{parent}(x_i))}{\sum_{x, x_1, \dots, x_4} \prod_j^{20} P(y_j/\text{parent}(y_j)) \prod_i^5 P(x_i/\text{parent}(x_i))}, \quad (4)$$

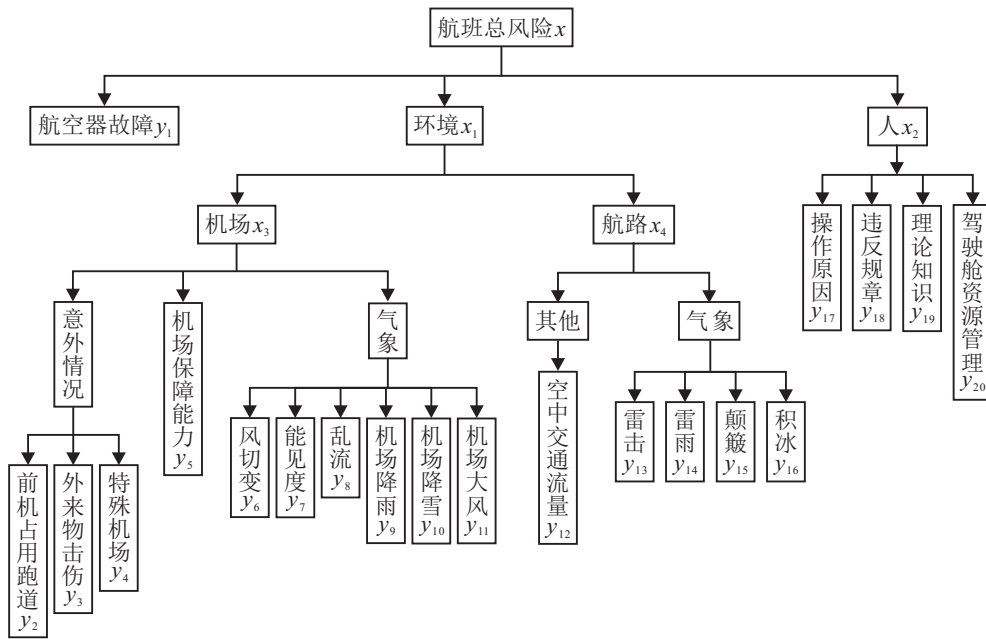


图1 基于数据的航班运行风险关键指标

其中 x_i^t, y_j^t 表示 t 时刻第 i 个隐含变量或第 j 个观测变量的状态值. 离散静态风险评估模型随着时间推移得到 t 个时间片组成的动态风险评估模型. 在本文案例中 $t = 10$, 每个时间片含有 5 个隐藏节点和 20 个观

测节点^[19].

动态贝叶斯网络推理如下: 各隐含节点在观测变量是某一状态的联合分布为

$$P\left(\frac{x^0, x_1^0, \dots, x_4^0, \dots, x_0^{10}, x_1^{10}, \dots, x_4^{10}}{y_1^0, y_2^0, \dots, y_{20}^0, \dots, y_1^{10}, y_2^{10}, \dots, y_{20}^{10}}\right) = \frac{P(x^0, x_1^0, \dots, x_4^0, \dots, x_0^{10}, x_1^{10}, \dots, x_4^{10}, y_1^0, y_2^0, \dots, y_{20}^0, \dots, y_1^{10}, y_2^{10}, \dots, y_{20}^{10})}{\sum_{x^0, x_1^0, \dots, x_4^0, \dots, x_0^{10}, x_1^{10}, \dots, x_4^{10}} P(x^0, x_1^0, \dots, x_4^0, \dots, y_1^0, y_2^0, \dots, y_{20}^0, \dots, y_1^{10}, y_2^{10}, \dots, y_{20}^{10})} \quad (5)$$

航班运行风险评估模型符合条件独立性假设, 因此

$$P\left(\frac{x^0, x_1^0, \dots, x_4^0, \dots, x_0^{10}, x_1^{10}, \dots, x_4^{10}}{y_1^0, y_2^0, \dots, y_{20}^0, \dots, y_1^{10}, y_2^{10}, \dots, y_{20}^{10}}\right) = \frac{\prod_{t,j} P(y_j^t / \text{parent}(y_j^t)) \prod_{t,k} P(x_k^t / \text{parent}(x_k^t))}{\sum_{x^0, x_1^0, \dots, x_4^0, \dots, x_0^{10}, x_1^{10}, \dots, x_4^{10}} \prod_{t,j} P(y_j / \text{parent}(y_j^t)) \prod_{t,k} P(x_k^t / \text{parent}(x_k^t))} \quad (6)$$

由此可得到 $t = 10$ 个时间片隐含节点的联合分布为

$$P\left(\frac{x_1^0, x_1^1, \dots, x_1^{10}}{y_1^0, y_2^0, \dots, y_{20}^0, \dots, y_1^{10}, y_2^{10}, \dots, y_{20}^{10}}\right) = \frac{P\left(\frac{x^0, x_1^0, \dots, x_4^0, \dots, x_0^{10}, x_1^{10}, \dots, x_4^{10}}{y_1^0, y_2^0, \dots, y_{20}^0, \dots, y_1^{10}, y_2^{10}, \dots, y_{20}^{10}}\right)}{\prod_{t=10,m} P(x_m^t / \text{parent}(x_m^t))} \quad (7)$$

以时间片 1 为例, 得到该时刻风险概率^[18]

$$P(x_1^0) = \frac{P\left(\frac{x_1^0, x_1^1, \dots, x_1^{10}}{y_1^0, y_2^0, \dots, y_{20}^0, \dots, y_1^{10}, y_2^{10}, \dots, y_{20}^{10}}\right)}{\prod_n P(x_1^n / \text{parent}(x_1^n))} \quad (8)$$

$t \in [0, 10], j \in [1, 20], k \in [1, 5], n \in [0, 10], m \in [2, 5]$.

根据式(5)~(8), 算法详细推理步骤^[20]如下.

Step 1: 根据航班运行风险评估模型的结构建立 n 个节点.

Step 2: 遍历 x_i 和 y_j 中每一个节点, 建立预推理模型时间片内节点的有向边.

Step 3: 遍历 x_i 和 y_j 中每一个节点, 建立预推理模型时间片间节点之间的有向边.

Step 4: 建立预推理模型中各节点的状态值.

Step 5: 遍历 x_i 和 y_j 中每一个节点, 依据历史数据统计值设置预推理模型时间片内节点的各项条件概

率.

Step 6: 遍历 x_i 和 y_j 中每一个节点, 依据历史数据统计值设置预推理模型时间片间节点的条件概率.

Step 7: 初始化模型参数.

Step 8: 观测值在线更新, 从 1 到 t 进行遍历.

Step 8.1: 建立预推理模型观测变量的状态和隐变量状态的所有组合状态;

Step 8.2: 根据条件概率表, 查找 x_i 和 y_j 处于指定状态以及其双亲节点也处于指定状态的条件概率;

Step 8.3: 确定双亲节点的联合概率, 如果双亲节点的联合概率更新, 则根据气象预测、流量控制、航空情报等条件变化, 从风控系统中取值, 自动更新先验概率, 返回 Step 8.1;

Step 8.4: 判断所有联合概率是否计算完成, 如果未完成, 则返回 Step 8.2.

Step 9: 计算不同风险范围的条件概率.

Step 10: 结果输出.

与经典算法相比, 本方案的优势在于观测值可根据实时的航空情报、天气等信息在线更新, 并根据气象预报、流量控制预测信息进行未来运行情况推断, 两种综合可动态调整风险防控策略. 节点信息更新过程在 2.2 节中详述.

1.3 动态贝叶斯网络学习

DBN 涉及结构学习和参数学习. 在结构学习中, 建立有效且最优的有向无环图是核心. 本文结合使用专家知识和数据学习两种方式. 参数学习在给定网络结构的基础上, 从训练数据中学习, 得到结点条件概率分布表^[15]. 参数学习最大期望算法, 是用期望的统计值代替实际统计值. 期望统计值来自参数, 而模型参数又依据期望统计, 因此过程需要迭代, 具体如下^[18].

1) 期望过程. 假设一个初始的模型参数 θ , 然后进行迭代, k 次迭代过程如下所示:

$$E[N(i, j)/\theta_0^k] = E\left[\sum_2^t I(x^{t-1} = i, x^t = j)/y^{1:t}\right] = \sum_2^t P(x^{t-1} = i, x^t = j)/y^{1:t}. \quad (9)$$

其中: t 表示模型中时间片的个数; θ 表示航班运行风险评估模型的条件概率; θ_0 表示初始条件概率; $I(E)$ 表示一个二值函数, 当 E 出现时为 1, 没出现时为 0; $N(i, j)$ 表示在给定一串数据序列时, 变量从状态 $i \rightarrow$

j 转移的次数; $E[N(i, j)/\theta_0^k]$ 表示期望值.

2) 最大化过程. 在给定数据下, 计算出 \log 似然值最大时的参数 θ , 表示为 $\theta^k = \arg \max_{\theta_0} Q(\theta/\theta_0^k)$, 其中 Q 是一个辅助函数, 表示为

$$Q(\theta/\theta_0^k) = E_{x^{1:t}} \left[P\left(\frac{y^{1:t}, x^{1:t}}{\theta} \middle/ \theta_0^k \right) \right]. \quad (10)$$

2 基于动态贝叶斯网络的航班运行风险控制

2.1 风险指标体系构建

根据国内航空公司 2008 年 ~ 2017 年总计 5 205 件不安全事件的详细数据, 统计各类风险因素, 将航班运行风险归类为环境、人为、机械 3 大类.

1) 环境因素. 包括起飞、目的地、备降以及航路的气象条件, 也包括鸟击、雷击、外来物等突发状况, 总计 3 315 起. 根据航班运行阶段的不同, 将环境因素分为机场环境状况和航路环境状况. 分析后得出重要因素, 举例描述如下.

①前机占用跑道: 当前机超时占用跑道, 后机已进入五边, 往往造成后续航班复飞, 而复飞阶段是航空事故率最高的时段. 经统计, 该类原因导致的不安全事件共有 306 起.

②外来物击伤: 外来物常造成航空器损伤, 严重危害航班运行安全. 该类原因导致的事件共有 352 起.

③机场保障能力: 保障能力取决于管制员、现场指挥员、保障设施以及助航设备等, 人员暂时短缺将使保障能力急速下降, 而设备设施的损坏也直接导致接收航班能力降级, 甚至改变飞行引导方式. 该类原因导致的事件共有 415 起.

④特殊机场: 特殊机场要求机组具备对应种类的资质和训练, 其区域环境复杂, 飞行操纵难度大. 该类原因导致的事件共有 19 起.

同理, 找出关键因素及发生次数如表 1 所示.

表 1 机场气象与航路环境关键因素

关键因素	统计次数	关键因素	统计次数
前机占用跑道	306	雪	20
外来物击伤	352	风	438
机场保障能力	415	交流流量	19
特殊机场	19	雷击	96
风切变	298	雷雨	18
能见度	357	颠簸	126
乱流	536	结冰	17
雨	298		

2) 人为因素.

①据统计, 操作原因导致的不安全事件共有 161

起,正常环境下机长操作原因112起,顺逆风时机组操作原因19起,高原机场顺逆风时机组操作原因10起,高原机场高温时机组操作原因11起,副驾驶操作原因9起。

②因违反规章而造成的不安全事件共259起,其中机组交叉检查不落实81起,机长飞行前准备不充分78起,机组监控不到位41起,违反标准操作程序59起。

③因理论知识掌握不当导致的不安全事件共有38起,其中公司培训不足18起,机组自身遗忘20起。

④因资源管理不到位导致的不安全事件有42起,包括机组情景意识差12起,机组注意力分配不当19起,机组搭配不合理11起。

3) 航空器故障是导致不安全事件的重要因素,共1390起。

由此完成对网络特征变量的选取,见图1。DBN网络特性表明模型中特征变量不宜过多,过多则计算复杂度几何级数增加,过少则无法准确反映动态变化。

2.2 基于动态贝叶斯网络的风险预测

各节点状态集合如下:航班总风险 x 状态分为3类,High表示人员伤亡、航空器受损、单发失效或重大财产损失等事故,Medium表示返航、备降、复飞、中断起飞等事件,而Low表示运行风险不明显。 $x_1 \sim x_4$ 分为IC、UC、RD,分别表示节点影响加重、不变和减小; $y_1 \sim y_{20}$ 用Y和N表示节点因素有影响和几乎不影响。

统计各节点的先验概率,通过样本结合专家意见,确定变量间初始条件概率表,各节点条件概率和

相邻时刻风险的条件转移概率举例见表2~表4^[21]。

表2 观测节点先验概率

节点	概率	节点	概率
y_1	0.183 0	y_{11}	0.110 0
y_2	0.055 7	y_{12}	0.009 7
y_3	0.085 2	y_{13}	0.015 3
y_4	0.002 3	y_{14}	0.008 5
y_5	0.072 7	y_{15}	0.005 7
y_6	0.059 1	y_{16}	0.004 5
y_7	0.131 8	y_{17}	0.027 8
y_8	0.040 3	y_{18}	0.028 9
y_9	0.049 4	y_{19}	0.004 5
y_{10}	0.002 3	y_{20}	0.016 5

表3 总风险条件概率

x	$P(x_2/x)$			$P(x_1/x)$			$P(y_1/x)$	
	IC	UC	RD	IC	UC	RD	Y	N
High	0.800	0.100	0.100	0.800	0.100	0.100	0.999	0.001
Medium	0.300	0.500	0.200	0.300	0.500	0.200	0.200	0.800
Low	0.100	0.100	0.800	0.100	0.100	0.800	0.040	0.960

表4 相邻时刻风险的条件转移概率

x	$P[x(t)/x(t-1)]$		
	High	Medial	Low
High	0.800	0.100	0.100
Medial	0.200	0.600	0.200
Low	0.100	0.200	0.700

转移网络反映了变量间随时间变化的概率依赖关系,是对先验网络的拓展,是SBN向DBN转变的关键。将转移网络与时间信息结合,得到风险动态评估网络如图2。

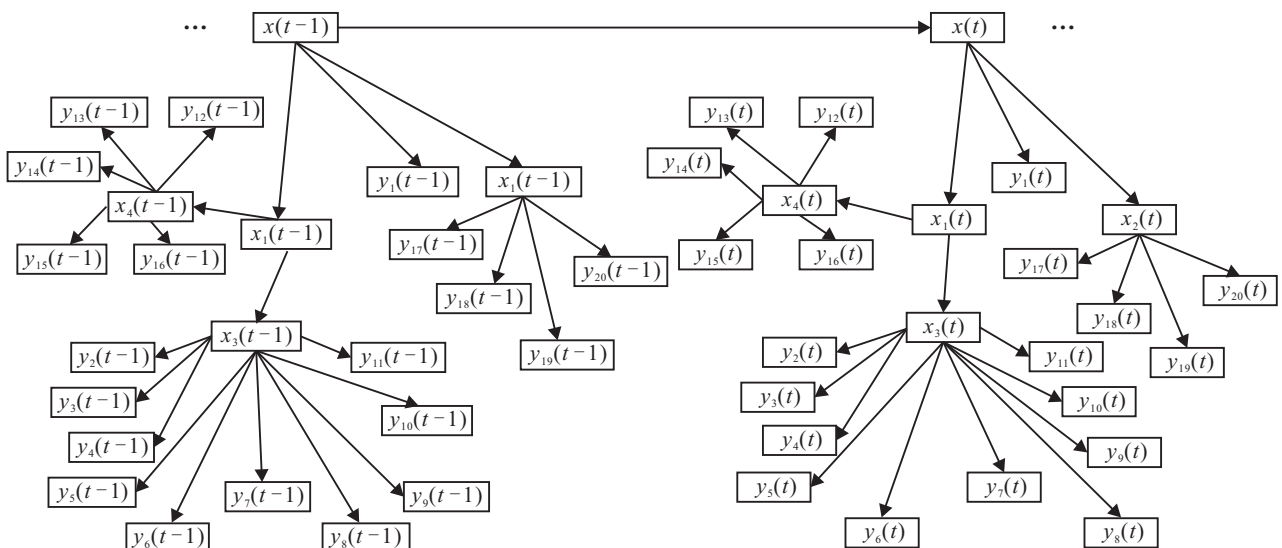


图2 航班运行风险动态贝叶斯网络

在对模型进行初始化后,从 $t - 1$ 到 t 时刻, $x_1 \sim x_4$ 和 $y_1 \sim y_{20}$ 任一节点状态发生变化,观测节点更新即触发网络推理算法,更新其他节点状态,最终推理结果动态变化^[22].

文献[5]中所述航空公司风险管控系统是节点信息更新的底层数据来源,其系统业务和数据架构见图3.其中:排班系统最早可提前一周发布飞行任务更换;航行情报系统除发布实时机场和航路数据外,还

可提前4小时发布流量控制信息;气象数据则主要使用实况电报和3~12小时有效期的气象预报.观测节点 $y_4, y_5, y_{17} \sim y_{20}$ 的状态与机场条件、机组技术、机组疲劳相关,由航班监控系统和机组疲劳监控系统根据飞行状态实时更新; $y_1, y_2, y_3, y_8, y_{12}$ 通过航行情报系统进行监控;其他节点使用航站气象雷达、自观设备等实时采集数据.

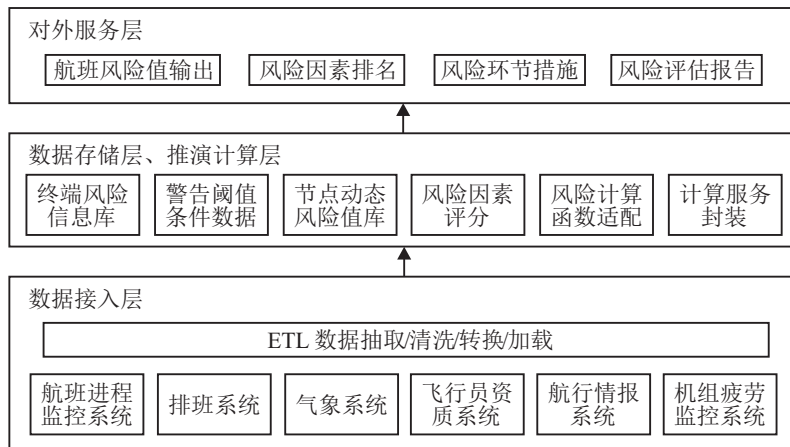


图3 风险管控系统业务和数据架构

3 实验与分析

3.1 案例选取

使用文献[5]中北京至浦东的航班,其中航路信息为“青岛上空FL37000处存在明显的对流天气,形成积雨云,雷暴云可能性高”.分析后可见,航空器保留故障属非关键系统,对运行造成影响概率小,可使用先验概率;机组中责任机长为新机长,执飞该航线经验少;查阅NOTAM可知,北京机场关闭一条跑道,保障能力下降.

起飞前风险预评估情况可见表5和表6,飞行过程中观测节点 y_6 在时刻9和时刻10发生了突变,评估值进行实时更新,如表7和表8.

表5 观测节点时刻信息

观测节点	时刻				
	1和2	3和4	5和6	7和8	9和10
y_1	(0.2, 0.8)	(0.2, 0.8)	(0.2, 0.8)	(0.2, 0.8)	(0.2, 0.8)
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
y_6	(0.1, 0.9)	(0, 1)	(0, 1)	(0, 1)	(0, 1)
y_7	(0, 1)	(0, 1)	(0, 1)	(0, 1)	(0, 1)
y_8	(0.1, 0.9)	(0, 1)	(0, 1)	(0, 1)	(0, 1)
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
y_{17}	(0.4, 0.6)	(0.4, 0.6)	(0.2, 0.8)	(0.2, 0.8)	(0.4, 0.6)
y_{18}	(0.1, 0.9)	(0.1, 0.9)	(0.6, 0.4)	(0.4, 0.6)	(0.8, 0.2)
y_{19}	(0.1, 0.9)	(0.1, 0.9)	(0.1, 0.9)	(0.1, 0.9)	(0.1, 0.9)
y_{20}	(0.3, 0.7)	(0.3, 0.7)	(0.2, 0.8)	(0.2, 0.8)	(0.3, 0.7)

表6 风险发生概率动态仿真结果(起飞前) %

Risk	时刻				
	1和2	3和4	5和6	7和8	9和10
High	0.48	0.08	1.90	0.54	5.25
Medium	2.32	1.22	53.10	7.96	49.90
Low	97.20	98.70	45.00	91.50	44.85

表7 观测节点在时刻9和时刻10的信息更新

时刻	观测节点				
	y_6	y_8	y_{12}	y_{17}	y_{20}
9	(1, 0)	(1, 0)	(0.8, 0.2)	(1, 0)	(0.5, 0.5)
10	(1, 0)	(1, 0)	(1, 0)	(1, 0)	(0.5, 0.5)

表8 风险发生概率动态仿真结果(起飞后) %

Risk	时刻				
	3和4	5和6	7和8	9	10
High	0.08	1.90	0.54	8.40	12.90
Medium	1.22	53.10	7.96	63.60	70.90
Low	98.70	45.00	91.50	28.00	16.20

3.2 起飞前计算

根据算例情况,将该航段运行过程分为10个时间片,间隔15 min,覆盖飞行各重要流程.其中:时刻1和时刻2处于起飞阶段,时刻3~时刻8处于巡航阶段,时刻9为进近阶段,时刻10为着陆阶段.

起飞前得到该航班的运行风险随时间的概率分

布见表6.

3.3 起飞前计算结果分析

参照联合国政府委员会对风险发生概率的定性描述, 33%~66%为中等可能, 大于66%为可能性较大, 大于90%为可能性很大. 由表6可见, 时刻1~时刻2即起飞30 min内, 机场、人员状态良好, 运行风险Low的概率是97.2%, 安全性高. 时刻3~时刻8对应于巡航阶段, 过程中Medium、Low的概率波动相对较大, 而High的波动较小. 其中: 时刻3~时刻4, 航路环境良好, 与起飞时刻相比, 安全性有所提升; 时刻5~时刻6, 航班至青岛上空, 受航路对流天气的影响, Medium明显增加即风险开始增大, 计算结果与航空公司当日值班飞行专家判断结果一致; 时刻7~时刻8, 航路天气转好, 风险很低. 在时刻9~时刻10进近着陆阶段, 由于能见度处于边缘, 机长经验能力欠缺, 风险提升但处于中等, 对应处置程序为“地面签派加强监控”, 航班仍可继续执行^[23].

3.4 起飞后计算

该航班因天气和流控原因延误至20:35起飞, 浦东机场21:00发布“机组报告R16/R17L有风切变”, 之后更新了TAF报告表明风切变不定且伴有低云. 根据案例情况, 机组处于执勤时间末期, 疲劳程度较高, 加上天气变化和流量限制等变化, 观测节点

$y_6, y_8, y_{12}, y_{17}, y_{20}$ 自动在线更新. 以时刻9~时刻10为例, 更新如表7, 推理得到该航班运行风险时间概率分布如表8. 因起飞后时刻1~时刻2已是过去式, 表中不再包含.

3.5 起飞后计算结果分析

如表8和图4, 时刻3~时刻8状态稳定, 在时刻9~时刻10飞机进近着陆时, 观测节点 y_6 在浦东风切变的影响下, 风险发生明显波动, Low的可能性急剧降低至16.2%, Medium上升至70.9%, High升至12.9%, 表明该时间段运行风险高, 复飞可能性大, 且重大事件发生可能性显著提升, 此时建议处置程序为“航班备降或返航”.

与实际飞行状态、航班运行风险管控系统事后数据记录进行对比, 如表9. 其中: 文中方法预测结果使用表8中风险处于Medium时的概率值; 风控结果则使用航班执行后的系统记录值, 数值范围为8~10时认为风险不可接受.

该航班实际运行结果为: 当航班飞至浦东机场后, 由于顺风超标仅能选择R16/R17L跑道落地, 在机组疲劳、能见度边缘与风切变的共同作用下, 机组进近尝试落地未果, 最终备降虹桥机场. 由表9可见, 预测结果与实际运行情况一致, 与风控系统事后记录数据一致, 算例验证了该方法的可行性.

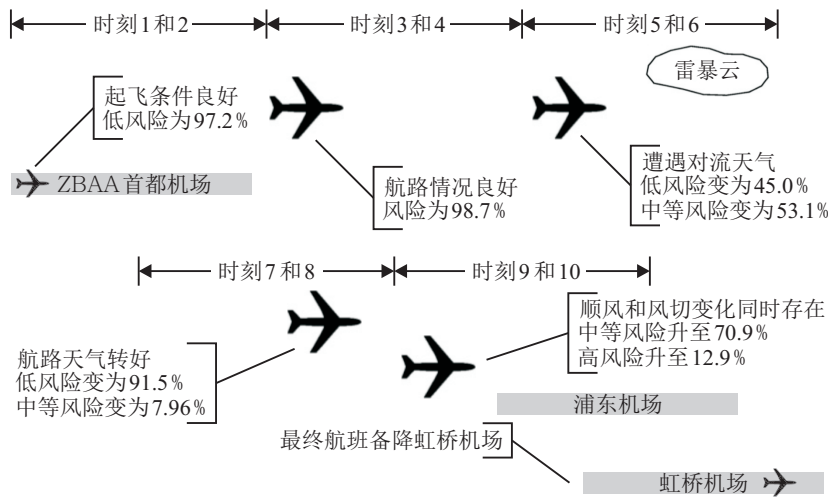


图4 风险概率时序变化图

表9 观测节点时刻信息

时刻	本文方法预测结果 / %	风控系统事后记录	实际操作
1和2	2.32	2.03	天气、跑道、飞行员状态良好
3和4	1.22	1.57	航路状况良好, 飞行员接通自动驾驶
5和6	53.1 (提醒机长注意, 地面人员加强监控)	4.20	航路遭遇雷暴, 为避免雷击, 机长接手操作绕飞雷雨
7和8	7.96	2.74	航路状况良好, 再次接通自动驾驶仪
9	63.6 (提醒机长注意, 地面做返航或备降预案)	7.87	风切变不定, 机组决定继续进近, 尝试降落
10	70.9 (建议返航或备降)	8.96	机组尝试落地未果, 最终备降虹桥机场

3.6 扩充检验数据量

扩大验证数据覆盖范围至2017年7月~9月雷雨季和12月冰雪季,统计返航、备降以及其他不安全事件的航班数据,对应方案中计算结果为“可能性较大”的出现次数,如表10所示.可见,对近200起不安全事件的总体预测准确度可高达80.4%,验证了该方案的有效性和可靠性.

表10 预测结果对比

	返航航班	备降航班	其他不安全事件
实际发生数	45	102	52
Medium 超过66%数量	37	87	36
预测准确度/%	82.2	85.3	69.2
总体预测准确度/%	80.4		

进一步分析发现,方案对返航备降类事件预测准确度很高,但对于其他类不安全事件的预测精度不足,究其原因在于图1中关键指标设置.图1来源于历史数据,当中较为完整地涵盖了恶劣天气、保障能力、流量控制等造成返航备降的重要因素;而对于其他类事件,尤其是机坪上擦碰和误操作等事件,指标覆盖完整度明显不足,导致预测结果不够理想.此缺陷还需民航业内各运行单位不断完善数据记录,在数据越发完整和精确的基础上,通过样本学习优化网络结构,优选网络参数,进而提升预测准确度.

4 结论

本文通过深入挖掘中国民航近10年不安全事件数据,提取出适用于航班运行风险评估的24项关键指标,建立了具有广泛适用性的风险预测动态贝叶斯网络;依靠不断更新航空情报、飞行员报告、流量控制数据、气象预报等网络参数,探索出一种航班运行风险动态预测新方法.真实航班算例结果表明,所提方法可有效识别和预测危险时段,具备可用性;在验证数据范围扩大后,结果显示总体预测准确度高于80%,说明该方法兼具有效性和可靠性.细致分析扩大验证数据后的结果发现,本文方法对返航备降等事件预测准确度很高,但受限于历史数据记录质量不高,导致地面操作类等不安全事件预测准确度不足,这指明了后续所需专项研究的方向.

参考文献(References)

[1] Wen K L. Risk assessment modeling in aviation safety management[J]. J of Air Transport Management, 2006, 12(5): 267-273.
 [2] James J H L, Gwo H, Han C C. Airline safety measurement using a hybrid model[J]. J of Air Transport

Management, 2007, 13(4): 243-249.
 [3] Huan J S. A quantitative model for aviation safety risk assessment[J]. Computers & Industrial Engineering, 2008, 54(1): 34-41.
 [4] 孙瑞山,唐晶.航班飞行安全风险快速评估工具研究[J].交通信息与安全,2013,31(2): 88-93.
 (Sun R S, Tang P. Rapid assessment tool for flight safety risk[J]. J of Transport Information and Safety, 2013, 31(2): 88-93.)
 [5] 王岩韬,李蕊,王皎皎,等.基于多因素分析的航班运行风险评估体系[J].天津工业大学学报,2014,33(3): 84-88.
 (Wang Y T, Li R, Wang J J, et al. A risk assessment system of flight operation based on multiple factor analysis[J]. J of Tianjin Polytechnic University, 2014, 33(3): 84-88.)
 [6] 王岩韬,卢飞,赵焱飞.安全管理模型修正的签派放行风险可拓评价[J].科技通报,2017,33(7): 217-223.
 (Wang Y T, Lu F, Zhao Y F. Research on dispatch release risk assessment with security management model amending[J]. Bulletin of Science and Technology, 2017, 33(7): 217-223.)
 [7] 王岩韬,李蕊,卢飞,等.基于运行数据的航班运行关键风险因素推断[J].交通运输系统工程与信息,2016,16(1): 182-188.
 (Wang Y T, Li R, Lu F, et al. Flight operation key risk factors inference based on operation data[J]. J of Transportation Systems Engineering and Information Technology, 2016, 16(1): 182-188.)
 [8] 王岩韬,唐建勋,赵焱飞.基于粗糙集和支持向量机的航班运行风险预测[J].中国安全科学学报,2017,27(9): 158-163.
 (Wang Y T, Tang J X, Zhao Y F. Prediction of risks in flight operations based on rough sets and support vector machine[J]. China Safety Science J, 2017, 27(9): 158-163.)
 [9] 胡继华,梁嘉贤.贝叶斯框架下快速公交的站间运行状态推断[J].交通运输系统工程与信息,2017,17(2): 126-135.
 (Hu J H, Liang J X. Inferring the travel states of bus rapid transit between neighboring stations within a bayesian framework[J]. J of Transportation Systems Engineering and Information Technology, 2017, 17(2): 126-135.)
 [10] Pearl J. Fusion, propagation, and structuring in belief networks[J]. Artificial intelligence, 1986, 29(3): 241-288.
 [11] Dean T, Kanazawa K. A model for reasoning about persistence and causation[J]. Computational Intelligence, 1989, 5(2): 142-150.
 [12] Heckman D. A tutorial on learning with Bayesian network[J]. Berlin Heidelberg: Springer-Verlag, 2008:

- 33-82.
- [13] Nodelman U, Shelton C R, Koller D. Continuous time Bayesian networks[C]. Proc of the 18th Conf on Uncertainty in Artificial Intelligence. Alberta: 2002: 378-387.
- [14] Xuan X, Murphy K. Modeling changing dependency structure in multivariate time series[C]. Proc of the 24th Int Conf on Machine Learning. Corvallis: ACM New York Press, 2007: 1055-1062.
- [15] 曹杰. 贝叶斯网络结构学习与应用研究[D]. 合肥: 中国科学技术大学信息科学技术学院, 2013: 1-7. (Cao J. Bayesian network stuction learning and application[D]. Hefei: School of Information Science and Technology, University of Science and Technology of China, 2013: 1-7.)
- [16] Murphy K P. Dynamic Bayesian networks: Representation, inference and learning[D]. Berkeley: Computer Science Division, University of California, 2002: 14-45.
- [17] Kay S M. Fundamentals of statistical signal processing[M]. New York: Prentice Hall PTR, 2002: 132-157.
- [18] 唐思思. 基于离散动态贝叶斯网络的信息安全风险评估方法的研究[D]. 沈阳: 东北大学信息科学与工程学院, 2013: 23-31. (Tang S S. Research on information security risk assessment based on the discrete dynamic Bayesian network[D]. Shenyang: College of Information Science and Engineering, Northeastern University, 2013: 23-31.)
- [19] German C, Ange'lica M, Lidia N C, et al. A dynamic Bayesian network for estimating the risk of falls from real gait data[J]. Springer J Medical & Biological Engineering & Computing, 2013, 51(1): 29-37.
- [20] 王双成, 高瑞, 杜瑞杰. 小时间序列的动态朴素贝叶斯分类器学习与优化[J]. 控制与决策, 2017, 32(1): 163-166. (Wang S C, Gao R, Du R J. Learning and optimization of dynamic naive Bayesian classifiers for small time series[J]. Control and Decision, 2017, 32(1): 163-166.)
- [21] 雷凯, 朱晓宁, 侯键菲. 多式联运网络风险传播建模与仿真[J]. 交通运输系统工程与信息, 2016, 16(3): 21-27. (Lei K, Zhu X N, Hou J F. Modeling and simulation of risk communication in multimodal trans networks[J]. J of Transportation Systems Engineering and Information Technology, 2016, 16(3): 21-27.)
- [22] 陈国胜. 基于动态贝叶斯网络的战场信息预测与评估[D]. 南京: 南京理工大学自动化学院, 2013: 24-34. (Chen G S. Based on dynamic Bayesian networks of battlefield information forecast and evaluation[D]. Nanjing: Automated Institute, Nanjing University of Science and Technology, 2013: 24-34.)
- [23] 魏照坤, 谢新连, 潘伟, 等. 基于朴素贝叶斯算法的船舶异常行为监测[J]. 交通运输系统工程与信息, 2017, 17(6): 147-154. (Wei Z K, Xie X L, Pan W, et al. Ship abnormal behavior detection based on naive Bayes[J]. J of Transportation Systems Engineering and Information Technology, 2017, 17(6): 147-154.)

作者简介

王岩韬(1982—), 男, 副教授, 硕士, 从事飞行运行安全与优化管理的研究, E-mail: CAUCwyt@126.com;

刘宏(1982—), 男, 讲师, 博士, 从事管制运行优化的研究, E-mail: hliu@cauc.edu.cn;

唐建勋(1980—)男, 讲师, 博士, 从事飞行运行优化调度的研究, E-mail: jxtang@cauc.edu.cn;

赵焱飞(1971—)男, 教授, 博士, 从事空中交通规划与管理等研究, E-mail: yfzhao@cauc.edu.cn.

(责任编辑: 齐 霖)