

DOI:10.16356/j.1005-2615.2023.05.012

基于数字孪生的航班链延误动态预测模型

丁建立, 吴 侯

(中国民航大学计算机科学与技术学院, 天津 300300)

摘要: 针对复杂多变的航班运行环境, 提出一种基于数字孪生的航班链延误动态预测模型, 以改善传统预测方法的精度及自适应性。模型基于数字孪生航班链系统构建, 采用滑动窗口下的多通道特征建模完成单元级航班延误预测, 并提出一种混合优化策略进行模型参数的动态优化, 最后通过孪生数据驱动的链式分析方法实现了全航班链的延误分析与修正。采用国内航班数据进行实验, 得到在各个窗口下的航班延误平均绝对误差 (Mean absolute error, MAE) 为 11.79 min, 低于其他基线模型和静态模型; 且引入孪生数据驱动分析和修正后, 紧随其后的航班预测误差比此前进一步降低了 6.44%。结果表明, 模型有利于数字孪生航班链系统实现虚实交互, 并具有优良的预测精度和自适应性。

关键词: 航班延误预测; 航班链; 数字孪生; 动态数据驱动; 虚实交互

中图分类号: U8; TP181 **文献标志码:** A **文章编号:** 1005-2615(2023)05-0859-09

A Dynamic Prediction Model of Flight Chain Delay Based on Digital Twin

DING Jianli, WU Yu

(College of Computer Science and Technology, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aiming at the complex and changeable flight operation environment, a dynamic prediction model of flight chain delay based on digital twin is proposed to improve the accuracy and adaptability of the traditional prediction methods. The model is constructed based on the digital twin flight chain system. Through the model, the unit-level delay prediction is accomplished by the multi-channel feature modeling method under the sliding windows, and the parameter optimization is completed by a hybrid optimization strategy. Moreover, the whole chain's delays are analyzed and corrected with the help of the twin data-driven strategy. Flight data in China are used to conduct the study. The mean absolute error (MAE) of flight delay prediction is 11.79 min, which is lower than those of other baseline models or static models, and the forecast error of subsequent flight delay can be reduced by 6.44% after twin data-driven analysis is implemented. The results show that the model is beneficial for the digital twin system to realize the virtual reality interaction, and has excellent prediction accuracy and adaptability.

Key words: flight delay prediction; flight chain; digital twin; dynamic data driven; virtual reality interaction

航班链是飞机一天内所执行航班任务的集合, 体现了前后序航班在时空上的紧密联系。研究航班链可以更好地揭示航班运行规律、预测延误时间。关于航班链延误预测问题, 国内外研究主要集中在航班延误预测和延误波及分析两

方面。

针对航班延误预测, 主流方法是使用数据挖掘算法学习数据间的隐含规律。早期, 算法相对简单, 如文献[1]分别采用决策树、随机森林、KNN(K-nearest neighbor)等算法预测航班延误情

基金项目: 国家自然科学基金民航联合基金重点项目(U2033205, U2233214)。

收稿日期: 2022-04-20; **修订日期:** 2022-10-28

通信作者: 吴侯, 男, 硕士研究生, E-mail: wy827349995@163.com。

引用格式: 丁建立, 吴侯. 基于数字孪生的航班链延误动态预测模型[J]. 南京航空航天大学学报, 2023, 55(5): 859-867.
DING Jianli, WU Yu. A dynamic prediction model of flight chain delay based on digital twin[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(5): 859-867.

况,并进行评估和比较;文献[2]采用支持向量机回归方法建立模型,并采用差分进化算法寻找最优参数,有效预测到港航班延误。此后,随着数据规模的增加,集成学习、深度学习等模型被更加广泛地应用,且在预测精度上获得改善。文献[3]针对航班延误数据分布不平衡的特点,在XGBoost模型上引入样本非线性赋权法,有效提高了延误分类预测的精度。文献[4]提出一种SE-DenseNet模型,在缓解深层网络梯度消失问题的同时,具有更强的特征提取能力。

延误波及分析主要基于复杂网络,对航空运输系统进行建模与仿真分析。Qing等^[5]将延迟传播动力学引入以机场为节点的时空网络中,并对东南亚和美国的航班案例进行分析比较;王春政等^[6]定义航班和机场智能体,通过考虑状态迁移及模型参数的设定,建模演化航班运行;吴仁彪等^[7]针对航班延误链式波及建模,根据航班链上的先后顺序划分三级机场,采用深度学习分析方法分析航班延误的波及影响。

近年来,虽然航班链延误预测研究成果颇丰,但在模型的动态性方面仍存在不足。大部分预测模型属于静态模型,而航班运行规律受各种复杂因素的影响,变化无常。在实际场景下,模型如果不能随航班运行态势及时修正,会面临预测精度降低的风险。

一些学者开始着力研究动态优化、数据驱动、实时计算等问题。例如,文献[8]采用集成学习思想,提出一种增量回归与分类树算法(Incremental classification and regression tree, I-CART),可以持续学习不断产生的航班动态运行信息,从而提高自适应性;文献[9]构建了一个链式预测模型,通过不断地迭代更新航班实际出发时间,提高了模型的预测准确性。然而,尽管上述研究已对动态性有所改善,但在模型整体设计、自适应性、预测精度等问题上,仍有较大提升空间。

数字孪生(Digital twin, DT)是一种集成多物理量、多尺度、多学科的技术,通过构建高保真数字模型,在对象全生命周期过程中达成虚拟世界和现实世界间的双向映射、反馈决策等目标^[10]。目前,数字孪生的相关研究已在空中交通管理等方面深入开展^[11]。

本文提出构建基于数字孪生的航班链延误动态预测模型。该模型将数字孪生技术引入到航班链中,覆盖全航班链,融合多源数据,达成航班数据的双向反馈与实时交互,有效提升航班运控能力。随着孪生系统的持续运行和虚实交互,模型不仅能利用机器学习方法动态预测航班延误时间,还可基于动态孪生数据和仿真分析的方法对链式延误加

以分析和修正,两者结合之下实现“由实入虚”和“以虚控实”,在确保模型优良自适应性的同时完成了精度提升。

1 航班数据特征生成

在航班链系统中,影响航班运行的因素包括飞行计划、机场天气、航班过站以及空中交通管理(包括流量控制、航路天气、空域受限、军事活动等)诸多方面。

由于本研究的空管数据相对短缺,无法支撑飞行过程的详细分析,因此暂先考虑从历史飞行数据中抽象出特定参数,通过仿真分析替代实际空管数据,待后续数据充足时可将此问题深入细化。

其余影响因素,按照作用机制不同,主要分为3类:(1)飞行计划数据,数据量大,规律稳定;(2)机场天气数据,规模适中,可以提前预测并收集;(3)航班过站数据,实时性强,数据量少,获取难度最大。在完成分类后,进行特征工程,以满足模型构建的需要,简要处理流程如下:

(1) 处理重复、空缺和异常值。以航班号、出发时间等作为关键字进行检索,删除飞行计划和航班过站数据中的多余样本;对空缺率高于20%的特征进行删除,对余下特征中的部分空缺值作适当填充(如天气特征参考前后时间段数据),不能填充的补零;比较实际时间与计划时间,删除航班过站数据中数值明显不符合实际的样本。

(2) 天气数据融合。机场天气数据每30 min获取1次,因此对每条飞行计划样本,按照离港时间上的就近原则关联到对应出发机场的天气。

(3) 航班链数据融合。按照飞行日期和飞机设备号关键字,选定目的机场与出发机场相同、且过站时间在限定时间内的两架航班,拼接成前后航班。依此类推,逐渐扩展为航班链。

(4) 连续特征离散化。将飞行计划、机场天气等数据的部分连续型特征离散化,例如,计划离港时间按小时划分到24个区间中;机场风向按照角度大小划分到8个方位上。

(5) 特征筛选。一方面,采用递归特征消除的方法,对数据集训练模型,并反复迭代,依次消去重要性排名最低的特征;另一方面,通过数据分析得到航班过站的一些关键特征。验证发现,飞行计划中的航班号、机场、机型和月份等特征最为重要;其次,机场天气中和航班过站中的特征也较为重要。处理后得到数据特征19个,特征信息如表1所示。

表 1 航班数据特征信息

类别	特征名	特征类型
飞行计划	航班号	类别型
	出发机场	类别型
	到达机场	类别型
	机型	类别型
	月份	整型
	日期	整型
	每周第 N 天	整型
机场天气	出发时段	整型
	风速	整型
	风向	整型
	能见度	整型
	气温	浮点型
	气象类型	类别型
	云底高度	整型
航班过站	前序航班离港延误	整型
	前序航班到港延误	整型
	剩余航班过站时间	整型
	平均离港延误	整型
	最近离港延误	整型

2 基于数字孪生的航班链延误动态预测模型

2.1 系统架构

结合数字孪生五维模型^[12]、航班链问题域,设计数字孪生航班链系统,作为模型运行的基础。系统架构如图 1 所示,包括 5 部分。

(1) 物理实体。物理实体是系统中的客观对

象,可以细分为单元级、系统级和复杂系统级 3 个层次。在本系统中,以航班为单元级实体,可以定位到当前场景下的运行状况;以航班链为系统级实体,可以感知航班运行态势,完成预测和优化;以区域内航班和机场网络为复杂系统级实体,能用于描述实体间的时空耦合关系,对全局演化进行分析。

(2) 虚拟实体。虚拟实体包括几何模型、物理模型、行为模型和规则模型等,从多尺度对物理实体进行刻画。以机场分布、飞机位置和航线规划等物理量搭建框架,得到几何模型和物理模型;以基于历史数据而学习到的航班延误经验和规律得到规则模型;以天气、机场过站信息等外部特征变化而引发系统状态改变的事件得到行为模型。结合上述 4 类模型,可以构建相对完整且有意义的虚拟航班链。

(3) 孪生数据。孪生数据驱动整个孪生系统的构建和运行,同时也是航班链延误动态预测模型的输入来源。孪生数据不仅包括从航班等物理实体中获得的动态数据,还包括系统等虚拟实体中累积的历史数据、预先规定或学习得到的知识数据等。

(4) 服务。服务对系统进行封装,通过物理实体的数据驱动虚拟实体中的规则演变,将有效结论通过接口直接提供给用户。在本系统中,服务包括航班延误预测、链式延误分析、关键节点计算、航班调度策略等。其中,核心是航班延误预测和链式延误分析。

(5) 连接。孪生系统的各部分可以相互连接,从而实现数据交互、模型驱动。例如,物理实体中的某架飞机即将到港,该信息发送至系统中后,首先更新服务状态,其次驱动虚拟实体运转,最后传

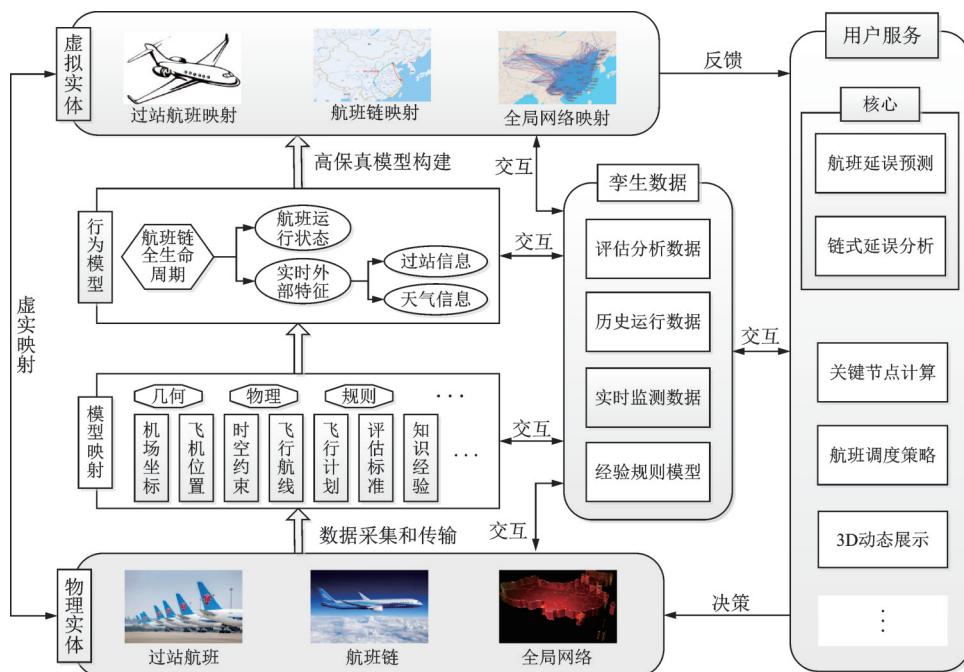


图 1 数字孪生航班链系统架构

Fig.1 Architecture of digital twin flight chain system

输至孪生数据,形成数据管理。虚拟实体可以从孪生数据获取数据、知识,结合预测模型加以分析,并将结论传输至服务接口供用户决策。用户决策后能形成反馈,推动系统完成新一轮循环。

2.2 模型框架

数字孪生系统在运行时需要处理源源不断的新数据,体现在模型算法上即应具备自适应能力。因此,基于孪生系统进一步设计了如图2所示的延误预测模型的总体框架。模型分为2部分:预测单元、链式延误分析算法。在图2中,符号 U 表示预测单元,主要对应单元级层次中的航班延误预测;符号 A 表示链式延误分析算法,主要对应系统级层次中的航班链式延误分析。




图2 航班链延误动态预测模型总体框架

Fig.2 Framework of dynamic delay prediction model

预测单元是一系列的独立模块,每个单元以航班特征数据作为输入,采用多通道特征建模的方法预测航班延误时间。在系统运行时,预测单元将对模型参数进行动态更新,以适应外部特征的变化。

链式延误分析算法将动态预测单元前后串联,考虑前序航班运行状况,以上游输出作为下游输入数据,基于孪生系统的动态数据驱动运行,完成全航班链的延误分析。

2.3 滑动窗口下的预测单元及混合优化

预测单元采用多通道特征建模构建,通过滑动窗口实现预测和参数动态优化。单元表达式为

$$d = M(s, w, p) \quad (1)$$

式中: d 为航班的离港延误时间; M 为预测单元; s 、 w 、 p 分别为航班对应的飞行计划、机场天气以及过站信息。这3类信息与航班中转过站密切相关,已有论证并常用于离港延误时间预测研究^[13]。

图3是预测单元内部结构,它从3类数据特征

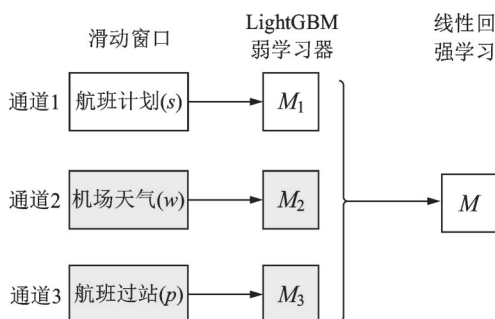


图3 预测单元结构

Fig.3 Structure of dynamic prediction unit

中学习隐含规律,联合预测航班离港延误时间。过程如下:

首先,将数据特征按飞行计划、机场天气和航班过站类别分为3个通道,并为每个通道添加滑动窗口,以聚焦当前时段下各类型的航班延误特征。每次,将当前窗口内的数据视作测试集,过往窗口的数据视作训练集。

其次,使用LightGBM算法^[14]分别对各自通道内的特征建模,学习隐含的航班延误规律,得到3个弱学习器 M_1, M_2, M_3 。LightGBM作为对梯度提升决策树(Gradient boosting decision tree, GBDT)的改进算法,其预测精度高、内存开销低、训练速度快,在航班延误预测问题上具有显著优势^[15]。

最后,使用线性回归算法对多通道的输出结果进行融合,得到最终的强学习器 M ,保证预测结果的准确性。最终表达式为

$$\hat{Y} = aX_1 + bX_2 + cX_3 \quad (2)$$

式中: \hat{Y} 为航班延误预测值; X_1, X_2, X_3 分别为3个通道的输出,均为矢量; a, b, c 表示权重系数,均为常数。

上述结构不仅有效避免了“维度诅咒”问题,提高了预测精度,而且使孪生系统具备了较好的可扩展性。例如,当空管信息加入时,可以开辟新通道4,对空管特征数据建模分析,将其对航班延误的影响纳入到强学习器中进行预测。总体上,数据维度考虑得越全面,孪生系统对真实世界的映射能力也越强,准确性和实时性将有所提升。

然而,随着滑动窗口的推移,系统运行环境可能发生巨大改变,模型需要对参数进行动态优化,以适应外部特征变化。

对弱学习器 M_1, M_2, M_3 ,设计了一种结合贝叶斯调参与增量迭代的混合优化策略。即每次窗口推移后,都先计算上一轮预测误差,再选定某个阈值 g ,考虑:当误差高于 g 时,将当前所有数据作为训练集,重新训练,并使用贝叶斯方法寻找最优参数;否则,直接对新数据快速增量迭代。

在上述策略中,贝叶斯调参是一种常见优化方法,适用于如LightGBM等参数众多的算法,缺点是寻优过程需要多次迭代地重建整个树模型,时间开销大。相对地,增量迭代则简化得多。增量迭代基于Boosting算法思想,指对新样本训练决策树,并累加到原有集成树上,从而实现修正。描述为

$$f_N(x) = \sum_{n=1}^N T(x; \theta_n) \quad (3)$$

式中: x 为样本特征值, θ_n 为第 n 棵树的参数, f_N 为

最终表达式, $T(\theta_n)$ 为第 n 棵树的表达式。式(3)表明,集成树模型是由 n 棵树相加得来。其中,参数 θ_n 的计算方法为

$$\theta_n = \arg \min L(y, f_{N-1}(x) + T(x; \theta_n)) \quad (4)$$

式中: L 为预定义的损失函数, y 为样本真实值。式(4)表明,训练第 n 棵树的目标正是为了拟合原模型预测值 $f_{N-1}(x)$ 与样本真实值 y 之间存在的残差。

参数 θ_n 唯一确定了树 $T(\theta_n)$ 的结构,因此求解 θ_n 的过程,实质是训练新树的过程。传统的GBDT算法以损失函数的负梯度拟合残差,以最小化均方差衡量信息增益,完成树的构建。LightGBM算法在此基础上,引入直方图算法,将总样本划分成 k 个区间 ($k \ll N$, N 为样本总数),使时间复杂度从 $O(N \times \text{特征数})$ 降低到 $O(k \times \text{特征数})$ 。此外,LightGBM还采用单边梯度采样、特征捆绑等策略,进一步优化了训练速度。

从这点考虑,增量迭代的代价仅仅是计算一棵树,而贝叶斯调参的代价则是多次重新构建完整模型。但是单独使用增量迭代,会使模型对新数据更敏感,对旧数据拟合效果变差,且随迭代次数增加结构逐渐臃肿,性能有所下降。因此,本文采用增量迭代与贝叶斯调参相结合的混合优化方式。

对于强学习器 M ,它只涉及3个权重系数,优化结果需要满足真实值 Y 与预测值 \hat{Y} 之差最小。易得

$$a^*, b^*, c^* = \arg \min (Y - \hat{Y}) = \arg \min (Y - (aX_1 + bX_2 + cX_3)) \quad (5)$$

利用最小二乘法拟合该多元线性模型,解得一组最优解 $\{a^*, b^*, c^*\}$,该组解代表了在上一轮窗口的最佳权重组合。由于航班延误影响因素具有时间连续性,可以继续用这组权重作为下一轮窗口的预测权重。

综上所述,参数优化过程与预测单元结构相呼应,通过改变通道权重,改善了预测单元对外部特征的适应能力。此外,混合优化可以在保持较高精度的同时,大幅提高优化速度。

2.4 孪生数据驱动的链式延误分析算法

预测单元在实际应用中存在局限性。通常,飞行计划和机场天气信息是已知的,但航班过站信息存在一定的不确定性,只有当实际发生时才能获取。因此,有必要引入链式延误分析算法,借助孪生系统的数据映射、仿真分析能力,提前预估航班过站信息,从而弥补短板,预测链式延误。

假设孪生系统在运行时,收集到航班链上第 i 架航班的实际离港时间,则第 $i+1$ 架航班过站信

息可以预估。具体地,由表1知航班过站信息特征包括5个数据特征,其中前3个特征与仿真驱动相关,计算方法如下。

前序航班的离港延误时间

$$d_i = t_i^{(\text{ad})} - t_i^{(\text{pd})} \quad (6)$$

式中: d_i 为第 i 架航班的离港延误时间, $t_i^{(\text{ad})}$ 为第 i 架航班的实际离港时间, $t_i^{(\text{pd})}$ 为第 i 架航班的计划离港时间。

前序航班的到港延误时间

$$e_i = d_i + \Delta \quad (7)$$

式中: e_i 为第 i 架航班的到港延误时间, Δ 为航班实际飞行时间与计划飞行时间之差,这是对空管等影响因素的抽象表示。

当前航班的剩余计划过站时间

$$r_{i+1} = t_{i+1}^{(\text{pd})} - t_i^{(\text{pa})} - e_i \quad (8)$$

式中: r_{i+1} 为第 $i+1$ 架航班的剩余计划过站时间, $t_{i+1}^{(\text{pd})}$ 为第 $i+1$ 架航班的计划离港时间, $t_i^{(\text{pa})}$ 为第 i 架航班的计划到港时间。

综上所述,航班链上航班过站信息可表示为

$$p_i = \begin{cases} p(s_i) & i=0 \\ p(s_i, t_{i-1}^{(\text{ad})}) & i \geq 1 \end{cases} \quad (9)$$

式中: p_i 为第 i 架航班的过站信息; s_i 为第 i 架航班的飞行计划信息,当 $i=0$ 时,表明是首架航班,不存在前序航班的影响,可直接根据飞行计划赋初值;当 $i \geq 1$ 时,表明存在前序航班,需要综合考虑前序航班实际离港时间 $t_{i-1}^{(\text{ad})}$ 。

图4是链式延误分析算法流程图,它描述了如何完整地预测航班链上所有航班的离港延误时间。首先为所有航班定义离港延误时间数组 d 。在首架航班飞行前,根据式(9)计算默认的初始值 p_0 ,从而输入延误预测单元中由式(1)得到 d_0 ,并由式(6)的变形进一步计算得到 $t_0^{(\text{ad})}$ 。此后,对后续航班依次循环计算 p_i , d_i 与 $t_i^{(\text{ad})}$,直至遍历整条航班链。最终,输出结果数组 d 。

需要注意的是,上述算法在不更新任何过站数据时,不确定性会随航班链逐层放大,导致预测结果出现偏差,因此需要结合实际观测数据加以修正。基于数字孪生数据映射的特性,在每次航班任务完成后,过站观测数据都将被输入到系统中。考虑到真实场景下,观测数据和预测数据均存在噪声,对二者采用数据同化的方式,加权求得最终的后验估计结果,表达式为

$$\bar{d}_i = \alpha^* z_i + (1 - \alpha) d_i \quad (10)$$

式中: $\alpha \in [0, 1]$, \bar{d}_i 为第 i 架航班的离港延误时间的后验估计结果, z_i 为第 i 架航班实际起飞后离港延误时间的观测值, d_i 为利用算法求得的第 i 架航班

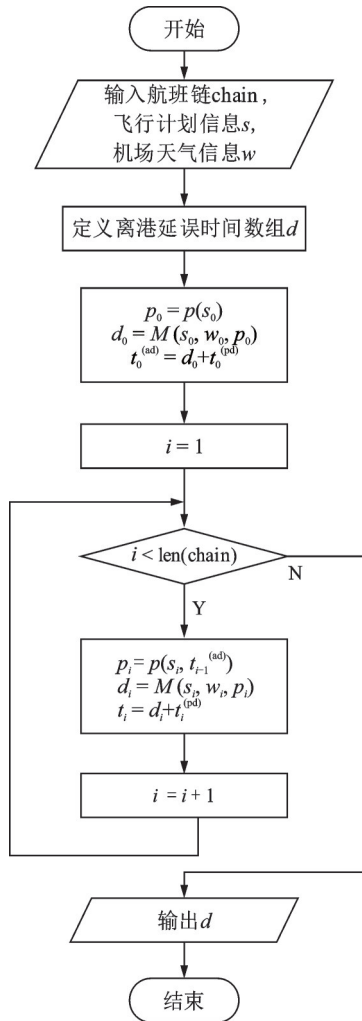


图4 链式延误分析算法流程

Fig.4 Flow of chain delay analysis algorithm

的先验估计。这样,孪生系统驱动的链式延误分析算法能不断利用 \bar{d}_i 修正航班链延误预测结果 d_i ,并指导后续的航班运控工作,实现虚实交互。

3 模型实验分析

3.1 实验描述

实验数据选自2017年全年国内8家大型机场之间的航班样本,机场信息见表2。依据第1节中的描述进行处理,得到117 260条数据样本。基于本文模型,从预测单元、链式延误分析算法这两方面着手,设计并开展实验。

实验结果以平均绝对误差(Mean absolute error, MAE)、均方根误差(Root mean square error, RMSE)作为度量标准,单位为min。它们用于衡量预测值与真实值之间的偏差和离散程度。数值越小,表明精度越高。计算公式为

$$\text{MAE} = \frac{1}{n} \sum_{k=1}^n |y_k - \hat{y}_k| \quad (11)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2} \quad (12)$$

表2 相关机场列表

Table 2 List of the airports

机场名	三字码
上海虹桥国际机场	SHA
北京首都国际机场	PEK
深圳宝安国际机场	SZX
广州白云国际机场	CAN
成都双流国际机场	CTU
杭州萧山国际机场	HGH
天津滨海国际机场	TSN

式中: n 为样本总数, y_k 为样本 k 的离港延误时间标签值, \hat{y}_k 为样本 k 的离港延误时间预测值。

实验中还涉及一些参数,在此说明:

(1) 动态预测单元中,滑动窗口大小设置为3 000,即每处理3 000条数据更新一次,共取前36个窗口。

(2) LightGBM模型优化过程中,阈值 g 设为动态值,数值上等于上次优化前计算的均方根误差。

(3) 链式延误分析算法中,飞行时间差 Δ 取自8个机场间最近3年的全部飞行记录,数据整体近似呈正态分布。实验中划分夏秋、冬春两季,并按照各个机场对之间的历史均值为 Δ 赋值。例如,在冬春航季从沈阳飞往深圳的航班, $\Delta = -5.83$ min;在夏秋航季从北京飞往上海的航班, $\Delta = 3.27$ min。

(4) 链式延误分析算法中,数据同化过程的 α 取0.9。该值是以0.1为步长,进行多次试验后所取得的最优拟合结果。

3.2 预测单元实验分析

3.2.1 预测精度分析

由于预测单元采用了多通道LightGBM特征建模的方法,此处选取单通道的LightGBM算法作为基线模型^[16]进行比较。在实验中,两者均采用相同的样本及特征数据,并同时在滑动窗口上进行训练和预测。

表3统计了两种预测方法求得的在所有窗口下MAE和RMSE的平均值。可见,本文预测单元的两个指标均低于LightGBM基线模型,平均MAE降低了0.35 min,平均RMSE降低了0.68 min,表明预测结果精度更高,也即对航班延误数据的学习能力更强。

表3 延误预测精度对比

Table 3 Comparison of delay prediction accuracy

算法	MAE/min	RMSE/min
本文预测单元	11.79	15.63
LightGBM	12.14	16.31

3.2.2 参数动态优化效果分析

首先验证参数动态优化过程的有效性,设计对比实验:试验 1 在系统运行全程对预测单元作参数优化,试验 2 则仅优化前 6 个窗口。

图 5 和图 6 是实验效果对比图。不难发现,从第 7 个窗口开始,两图中试验 1 的曲线均基本位于试验 2 的曲线下,说明试验 1 的各时间窗下的预测精度更高。定量计算表明,持续优化后的预测单元,在所有窗口下的平均 MAE 降低了 0.73 min,平均 RMSE 降低了 1.21 min,该指标相对于静态模型的误差分别降低了 5.87% 和 7.17%。可以认为,进行动态优化后,模型能做到随外部特征的改变主动调节参数,避免预测精度的降低,也即优化过程对模型自适应能力具有提升作用。

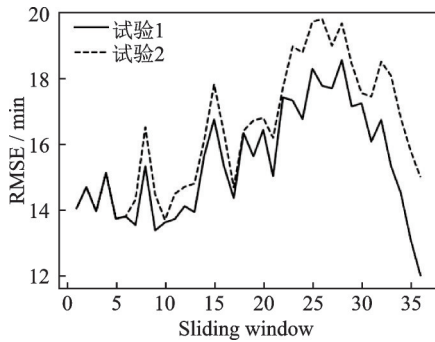


图 5 参数优化效果对比 (MAE)

Fig.5 Comparison of parameter optimization (MAE)

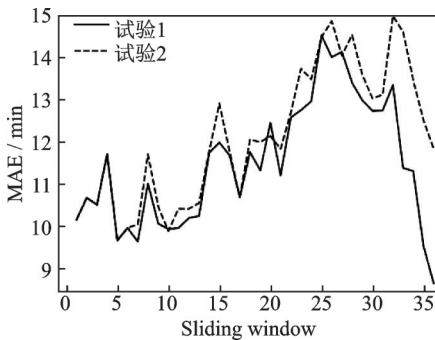


图 6 参数优化效果对比 (RMSE)

Fig.6 Comparison of parameter optimization (RMSE)

观察发现,在系统运行的中后半段,优化效果更明显。一方面,得益于数据量和优化次数的增加,当前参数更加适应环境特征,新模型比旧模型的预测能力更强;另一方面,后半段数据主要对应夏秋季航班,天气条件较差,航班延误更频繁,所以优化后的自适应效果更加显著。

进一步地,对预测单元中的 LightGBM 模型分别使用增量迭代、贝叶斯调参两种方法进行优化,从速度和精度两方面作比较,验证混合优化策略的高效性。

实验结果如表 4 所示。单纯使用增量迭代,虽然可以模型更新速度最快,但预测误差过高;单纯使用贝叶斯调参,可以保证预测精度,但每一轮更新都需要大量时间。总体上,采用本文提出的混合优化策略,一方面可以将调参次数从 105 次降低到 63 次,节省约 40% 的时间;另一方面能使预测精度远高于单纯的增量迭代方法,且同样不低于贝叶斯调参方法。说明该策略兼顾了优化速度与预测精度。

表 4 不同优化策略效果对比

优化策略	贝叶斯调参次数/次	MAE/min	RMSE/min
混合优化	63	11.79	15.63
增量迭代	0	12.70	16.82
贝叶斯调参	105	11.82	15.61

3.3 链式延误分析算法实验分析

链式延误分析算法需要针对航班链进行实验。首先从 8 家目标机场组成的航线网络中,筛选航班链数据集,所选用的航班链样本应依次满足如下要求:

(1) 设目标机场集合为 S,则样本只选自飞机从飞入 S 之后到飞出 S 之前的部分,仅表示飞机实际执行的完整航班链的一个子集。故若有出发或到达机场不属于 S 的航班,需要从此截断,取其符合要求的连续子段。

(2) 入选的每条样本中应至少包含 4 架航班,以便充分观察航班延误在链上的波及情况。实验中,以每条航班链的首架航班作为当前航班(层级为 0),其余航班作为后续航班,预测后续航班的离港延误时间。

其次确定观测数据与先验估计之间的最优权重。取 $\alpha \in [0, 1]$,步长为 0.1,进行多次试验,结果见表 5。当 $\alpha = 0.9$ 时,模型整体精度最高,也即设定观测数据与先验估计权重之比为 9:1。

表 5 不同 α 取值下离港延误时间 MAE

α	各航班层级 MAE/min			平均 MAE/min
	第 1 级	第 2 级	第 3 级	
0.0	11.65	12.81	13.68	12.71
0.1	11.44	12.72	13.61	12.59
⋮	⋮	⋮	⋮	⋮
0.7	10.98	12.33	13.02	12.11
0.8	10.97	12.29	12.93	12.06
0.9	<u>10.90</u>	<u>12.17</u>	12.91	<u>11.99</u>
1.0	10.92	12.19	<u>12.90</u>	12.00

此后,再验证参数 Δ 的设置对实验的影响。经分析,按照历史数据分析选定参数 Δ ,比起直接将 Δ 设为0(即不考虑空管因素),平均每一层级的航班延误时间MAE可下降0.13 min,表明考虑空管因素影响、使用参数仿真分析能有效提升算法预测性能。在未来系统不断完善的发展趋势下,参数 Δ 可采用实时空管数据进行细化,持续改善算法精度。

最后,为验证算法性能,设计对比试验:试验1将航班链上各航班孤立开来,即不引入链式延误分析算法;试验2引入链式延误分析算法;试验3不仅引入该算法,还采用当前航班的离港延误观测数据进行驱动。

图7是实验结果,其中纵轴是指标MAE,横轴是航班在航班链中所在的层级,层级为0的航班即为当前航班。可以看出,3次试验中模型的预测误差都会逐渐增大,这是由于延误波及过程中的不确定性在逐层累积,符合2.4节中的分析。




图7 链式延误分析算法实验结果

Fig.7 Results of chain delay analysis algorithm

显然,试验3在各级的预测误差最小,这是受当前航班观测值的驱动更新影响,保障了最佳效果。经计算,试验3在后续第1级航班延误预测中,MAE为10.90 min,相较于试验2的11.65 min下降了6.44%。当然,随着延误的逐层波及,差距越来越小,说明优势逐渐耗尽,因此需要不断地进行修正。此外,试验1没有考虑航班延误的波及效应,因而预测效果最差,且差距始终存在。

综上所述,实验结果表明,链式延误分析算法可以有效解决航班延误预测中信息不确定的问题,分析航班链上各航班的离港延误时间;算法充分表达了数字孪生系统中数据驱动的特性,通过数据反馈获得了更优的预测精度,具有稳定、动态、准确的特点。

4 结 论

本文将数字孪生技术引入到航班运控工作中,设计了数字孪生航班链系统架构,并剖析了物理实

体、虚拟实体、孪生数据、服务与连接等组成要素。进一步地,提出基于数字孪生的航班链延误动态预测模型,建立起虚实航班链之间的双向映射,可解决传统静态模型自适应性和预测精度不足的问题。

主要结论有:(1)对航班数据特征作划分,并分别在不同通道内建模学习,可具有更强的航班数据学习能力,取得比基线模型更高的预测精度。(2)滑动窗口下的动态优化过程赋予了模型自适应性,且对LightGBM算法采用增量迭代与贝叶斯调参相结合的混合优化策略可以兼顾精度和速度,更为高效。(3)采用孪生数据驱动的链式延误分析算法,可减少延误波及过程中不确定性因素的影响,修正分析结果,降低误差。

本文在数字孪生系统建模上进行了一定程度的抽象,具体细节还有待完善。后续将以当前工作为基础,继续讨论误差修正、算法改进、数据同化等问题,推动数字孪生技术在民航领域、航班链问题上的应用。

参考文献:

- [1] CHOI S, KIM Y J, BRICENO S, et al. Prediction of weather-induced airline delays based on machine learning algorithms[C]// Proceedings of 2016 IEEE/AIAA the 35th Digital Avionics Systems Conference. Sacramento, USA: IEEE, 2016: 1-6.
- [2] 罗赞骞, 陈志杰, 汤锦辉, 等. 采用支持向量机回归的航班延误预测研究[J]. 交通运输系统工程与信息, 2015, 15(1): 143-149, 172.
LUO Yunqian, CHEN Zhijie, TANG Jinhui, et al. Flight delay prediction using support vector machine regression[J]. Journal of Transportation Systems Engineering and Information Technology, 2015, 15(1): 143-149, 172.
- [3] 唐红, 王栋, 宋博, 等. 基于非线性赋权XGBoost算法的航班延误分类预测[J]. 系统仿真学报, 2021, 33(9): 2261-2269.
TANG Hong, WANG Dong, SONG Bo, et al. Classification of flight delay based on nonlinear weighted XGBoost[J]. Journal of System Simulation, 2021, 33(9): 2261-2269.
- [4] 吴仁彪, 赵婷, 屈景怡. 基于深度SE-DenseNet的航班延误预测模型[J]. 电子与信息学报, 2019, 41(6): 1510-1517.
WU Renbiao, ZHAO Ting, QU Jingyi. Flight delay prediction model based on deep SE-DenseNet[J]. Journal of Electronics & Information Technology, 2019, 41(6): 1510-1517.
- [5] QING C, SAMEER A, VU N D. A spatial-temporal

- network perspective for the propagation dynamics of air traffic delays[J]. *Engineering*, 2021,7(4): 452-464.
- [6] 王春政, 胡明华, 杨磊, 等. 基于Agent模型的机场网络延误预测[J]. *航空学报*, 2021,42(7): 452-465.
WANG Chunzheng, HU Minghua, YANG Lei, et al. Airport network delay prediction based on Agent model[J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(7): 452-465.
- [7] 吴仁彪, 赵娅倩, 屈景怡, 等. 基于CBAM-CondenseNet的航班延误波及预测模型[J]. *电子与信息学报*, 2021, 43(1): 187-195.
WU Renbiao, ZHAO Yaqing, QU Jingyi, et al. Flight delay propagation prediction model based on CBAM-CondenseNet[J]. *Journal of Electronics & Information Technology*, 2021, 43(1): 187-195.
- [8] 王丹, 王萌, 王晓曦, 等. 用于航班延误预测的集成式增量学习算法[J]. *北京工业大学学报*, 2020, 46(11): 1239-1245.
WANG Dan, WANG Meng, WANG Xiaoxi, et al. Ensemble of incremental learning algorithm for flight delay prediction[J]. *Journal of Beijing University of Technology*, 2020,46(11): 1239-1245.
- [9] CHEN J, LI M. Chained predictions of flight delay using machine learning[C]//*Proceedings of AIAA SciTech 2019 Forum*. San Diego: AIAA, 2019: 1661-1676.
- [10] TAO F, CHENG J F, QI Q L, et al. Digital twin-driven product design, manufacturing and service with big data[J]. *The International Journal of Advanced Manufacturing Technology*, 2018, 94(9): 3563-3576.
- [11] YURKEVICH E V, STEPANOVSKAYA I A. Controlling the security of the airport airspace using the digital twin[C]//*Proceedings of the 13th Multiconference on Control Problems*. Saint Petersburg: IOP Publishing, 2021: 012128.
- [12] 陶飞, 刘蔚然, 张萌, 等. 数字孪生五维模型及十大领域应用[J]. *计算机集成制造系统*, 2019, 25(1): 1-18.
TAO Fei, LIU Weiran, ZHANG Meng, et al. Five dimension digital twin model and its ten applications [J]. *Computer Integrated Manufacturing Systems*, 2019,25(1): 1-18.
- [13] 何坚, 果红艳, 姚远, 等. 基于有效中转时间预测的不正常航班恢复技术[J]. *北京航空航天大学学报*, 2022,48(3): 384-393.
HE Jian, GUO Hongyan, YAO Yuan, et al. Irregular flight recovery technique based on accurate transit time prediction[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2022,48(3): 384-393.
- [14] KE G L, MENG Q, FINLEY T, et al. LightGBM: A highly efficient gradient boosting decision tree[C]//*Proceedings of Advances in Neural Information Processing Systems 30*. San Diego, USA: Neural Information Processing Systems Foundation, 2017: 3149-3157
- [15] YE B J, LIU B, TIAN Y, et al. A methodology for predicting aggregate flight departure delays in airports based on supervised learning[J]. *Sustainability*, 2020, 12(7): 2749-2761.
- [16] 丁建立, 孙玥. 基于LightGBM的航班延误多分类预测[J]. *南京航空航天大学学报*, 2021, 53(6): 847-854.
DING Jianli, SUN Yue. Multi-classification prediction of flight delay based on lightGBM[J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2021, 53(6): 847-854.

(编辑: 张蓓)