

## 基于 LightGBM 的分阶段多模态航迹预测方法

胡小兵<sup>1a</sup>, 李伯阳<sup>1b</sup>, 柯 劼<sup>2</sup>

(1. 中国民航大学 a. 安全科学与工程学院; b. 中欧航空工程师学院, 天津 300300; 2. 上海飞机设计研究院, 上海 201210)

**摘要:** 航空器四维(4D, four-dimensional)航迹预测作为基于航迹运行(TBO, trajectory-based operation)的关键技术之一, 具有重要的意义。针对数据差异性不足、关键数据获取难度大、模型复杂度高、泛化性差等问题, 本文提出一种基于轻量级梯度提升机(LightGBM, light gradient boosting machine)的分阶段多模态航迹预测方法(LightGBM-based PMTPM, LightGBM-based phased multimodal trajectory prediction method)。该方法能够智能识别航空器所处的飞行阶段, 并根据航空器自身传感器提供的数据, 使用机载计算机预测航空器的4D航迹及实时质量。实验结果表明, 在所有飞行阶段, LightGBM-based PMTPM 相较于基于反向传播神经网络的分阶段多模态航迹预测方法(BPNN-based PMTPM, back propagation neural network-based phased multimodal trajectory prediction method)都表现出更优的预测性能, 均方根误差(RMSE, root mean square error)分别降低了64.86%、13.15%、80.88%、77.46%、86.45%、3.46%、19.22%; LightGBM-based PMTPM 的平均评估时间为59.890 ms, 满足航空器4D航迹预测的准确性和实时性要求。

**关键词:** 四维(4D)航迹预测; 基于航迹运行(TBO); 轻量级梯度提升机(LightGBM); 多模态航迹预测

**中图分类号:** V249.4 **文献标志码:** A **文章编号:** 1674-5590(2026)01-0001-09

### LightGBM-based phased multimodal trajectory prediction method

HU Xiaobing<sup>1a</sup>, LI Boyang<sup>1b</sup>, KE Jie<sup>2</sup>

(1a. College of Safety Science and Engineering; 1b. Sino-European Institute of Aviation Engineering, CAUC, Tianjin 300300, China;

2. Shanghai Aircraft Design & Research Institute, Shanghai 201210, China)

**Abstract:** Four-dimensional (4D) trajectory prediction of aircraft, as one of the key technologies of trajectory-based operation (TBO), is of great significance. To address issues such as insufficient data diversity, difficulty in acquiring critical data, high model complexity and poor generalization, this paper proposes a light gradient boosting machine (LightGBM)-based phased multimodal trajectory prediction method (LightGBM-based PMTPM). The method can intelligently identify the flight phase of the aircraft and, based on data from the aircraft's own sensors, predict the 4D trajectory and real-time quality of the aircraft using an onboard computer. Experimental results show that, during all flight phases, the LightGBM-based PMTPM outperforms the back propagation neural network-based phased multimodal trajectory prediction method (BPNN-based PMTPM) in predictive performance, with root mean square error (RMSE) reductions of 64.86%, 13.15%, 80.88%, 77.46%, 86.45%, 3.46% and 19.22%, respectively. The average evaluation time of the LightGBM-based PMTPM is 59.890 ms, meeting the accuracy and real-time requirements for 4D trajectory prediction of aircraft.

**Key words:** four-dimensional (4D) trajectory prediction; trajectory-based operation (TBO); light gradient boosting machine (LightGBM); multimodal trajectory prediction

近年来,随着社会经济的快速发展和全球贸易的迅速恢复,航空运输业迎来了新的发展机遇。然而,随着空中交通流量的持续增长,航班延误和流量控制等问题严重降低了空中交通管理系统的运行效率。

为解决这一问题,国际民航组织(ICAO, International Civil Aviation Organization)正在将空中交通管理从基于航空器运行的传统模式,转变为基于航迹运行(TBO, trajectory-based operation)的新模式<sup>[1]</sup>。其中,精

确的四维(4D, four-dimensional)航迹是实现 TBO 运行的核心,也是欧盟提出的欧洲单一天空空中交通管理研究(SESAR, single European sky air traffic management research)计划和美国联邦航空管理局规划的新一代空管系统(NextGen, next generation air transportation system)运营的基础<sup>[2]</sup>。在 SESAR 理念的指导下,欧洲开发了一套地面航迹预测工具<sup>[3]</sup>。该工具的核心思想是在遵循地面空管约束条件的前提下,利用航迹预测软件计算航空器最优航迹,并将其发送至地面系统,以验证飞行间隔是否满足相关标准<sup>[4]</sup>。

航迹预测是指利用当前的飞行数据、气象数据、飞行计划以及航空器性能模型,计算并预测航空器在未来一段时间内的航迹<sup>[5]</sup>。目前航迹预测方法主要分为以下 3 个研究方向。

(1) 基于状态估计理论的方法。由于航空器运动的复杂性,航迹预测可以被看作一个随机线性混杂系统的预测问题。这种方法通过航空器运动方程建立状态方程的转移矩阵,并利用卡尔曼滤波算法进行最优估计<sup>[6]</sup>。吕波等<sup>[7]</sup>基于改进的扩展卡尔曼滤波方法,结合多新息理论有效降低了预测误差。交互式多模型可以解决多模型算法的高复杂度问题<sup>[8]</sup>。倪育德等<sup>[9]</sup>将广播式自动相关监视(ADS-B, automatic dependent surveillance-broadcast)系统信息与残差-均值交互多重模型算法和意图推算算法结合开展航迹预测。然而,这些方法容易受到错误数据的干扰,且计算时间较长,实时性较差。

(2) 基于机器学习的方法。Lymperopoulos 等<sup>[10]</sup>将基于雷达数据的航迹预测方法与基于航空器连续动态模型的方法相结合,显著降低了航空器起飞过程中位置的不确定性。谭伟等<sup>[11]</sup>利用基于遗传算法的反向传播神经网络(BPNN, back propagation neural network)建立了机动目标航迹预测模型,结果显示该模型具有更高的学习精度和更快的收敛速度。冯霞等<sup>[12]</sup>构建了长时 4D 航迹预测模型。然而,这些研究大多使用 ADS-B 数据,飞行状态参数较少且时间间隔不固定,航空器质量通常为估计值,对实际情况下航空器的质量敏感度较低。

(3) 基于动力学模型的方法。该方法主要采用点质模型结合各类机型性能参数来实现航迹的实时预测。Weitz<sup>[13]</sup>通过分析航空器受力,建立了有风和无风条件下航空器点质模型的动力学和运动学方程。王超等<sup>[14]</sup>根据基本飞行模型将 4D 航迹分解为 3 个剖面;张军峰等<sup>[15]</sup>建立了不同剖面的意图模型,并通过预测步

长对 4D 航迹进行了计算。然而,航空公司将速度意图和航空器质量等参数视为关键参数,因此,外界很难获取到高质量的航空器性能数据。Schultz 等<sup>[16]</sup>提出了一种自适应爬升算法,通过观测到的航空器航迹数据动态调整建模的航空器质量以改善爬升航迹预测质量。还有一些学者也进行了类似的研究<sup>[17-18]</sup>。

目前,研究人员使用的方法面临以下两大问题。

第一是数据的差异性与模型的复杂性。现阶段研究者通常基于 ADS-B 数据进行深度学习分析,对数据整体打包进行模型训练。这会导致以下几个缺陷。

(1) 即使是相同的航班,不同的气象情况、差异化的航路选择以及临时的空管指令都会导致生成的数据相对关联性较低。

(2) 航空器在不同飞行阶段的飞行数据存在显著差异,目前使用深度学习的研究较少考虑此问题。

(3) 收集到的数据相对于真实数据存在样本偏差,由测量设备引起的误差、空地数据传输间的误差无法避免。

(4) 打包训练大大增加了模型的复杂度,大量参数增加了模型的训练时间,并且模型的结果对这些参数具有高度依赖性。

(5) 现有的机载计算机无法承载数据量大、高复杂度的模型。按照相关适航法规,机载计算机需优先满足极端环境下的稳定工作,所以机载计算机更新速度差、算力低。这些都会影响模型预测效果的准确度。

第二是数据获取与模型的泛化性,存在以下几个问题。

(1) 关键参数如速度意图和航空器质量是封闭的,无法开源获取。虽然有学者通过将真实质量转换成等效质量进行研究<sup>[16,19]</sup>,但结果不够直观。

(2) 现有的训练数据主要来自航空器在平稳状态下的运行记录,对于极端条件下的数据则较为缺乏。由于训练数据的局限性,模型在极端飞行条件下的航迹预测精度可能会受到较大影响,难以保证预测的可靠性。

针对以上问题,本文基于 SESAR 理念,考虑航空器自身为飞行数据的第一记录者,在参考机载电子设备算力匹配的情况下,提出了一种基于轻量级梯度提升机(LightGBM, light gradient boosting machine)的分阶段多模态航迹预测方法(LightGBM-based PMTPM, LightGBM-based phased multimodal trajectory prediction method),其能够智能识别航空器所处的飞行阶段,并根据航空器自身传感器提供的发动机推力、真空

速、飞行高度等相应数据,预测航空器的 4D 航迹以及实时质量。

## 1 问题建模

### 1.1 简要工作介绍

首先,基于航空器基础资料(BADA, base of aircraft data)<sup>[20]</sup>,参考航空器气动布局、推力模型、阻力模型和油耗模型等,构建了航空器动力学和运动学模型。其次,通过文献[14]提出的基本飞行模型,参考航空器在实际运行过程中的飞行意图,构建了航空器高度和速度的垂直剖面。最后,针对目前机载电子设备在航迹预测中效率低、精度差的问题,本文提出了 Light-GBM-based PMTPM。该模型能够智能识别航空器所处的飞行阶段,并为不同飞行阶段单独构建模型,通过模型快速获取航空器的实时质量。将这种方法与BPNN、基于BPNN的分阶段多模态航迹预测方法(BPNN-based PMTPM, BPNN-based phased multimodal trajectory prediction method)和LightGBM-based PMTPM 进行对比,证明本文提出方法的有效性和实用价值。技术路线图如图 1 所示,其中,选择均方误差(MSE, mean square error),均方根误差(RMSE, root mean square error),决定系数  $R^2$ ,平均绝对误差(MAE, mean absolute error)和平均绝对百分比误差(MAPE, mean absolute percentage error)作为回归评价指标。

### 1.2 航空器模型建立

#### 1.2.1 全能量模型

全能量模型是利用 BADA 模型进行航迹预测的关键<sup>[21]</sup>。通过将航空器视为一个质点,分析其受力并使用牛顿力学和能量法对航空器整体进行数学建模,以确定航空器速度、高度、推力和阻力之间的关系。

航空器总机械能对时间  $t$  求导后的表达式为

$$(T_{tr} - D)V = mg_0 \frac{dh}{dt} + mV \frac{dV}{dt} \quad (1)$$

式中: $T_{tr}$  为航空器推力; $D$  为航空器阻力; $V$  为航空器真空速; $m$  为航空器质量; $g_0$  为重力加速度(值为  $9.80665 \text{ m/s}^2$ ,假设重力加速度不随飞行高度变化而变化); $h$  为航空器高度。

进行移项整合处理可得

$$\frac{dh}{dt} = \frac{(T_{tr} - D)V}{mg_0} \left[ 1 + \left( \frac{V}{g_0} \right) \left( \frac{dV}{dh} \right) \right]^{-1} \quad (2)$$

航空器在大气中运行时,仪表显示高度通常为气压高度而不是大地高度,本文引入爬升或下降率(ROCD, rate of climb or descent),即航空器气压高度  $H_p$  随时间

的变化,由于其可以消除大气环境变化带来的扰动,所以是表征航空器性能的首选方式。其计算公式为

$$e_{ROCD} = \frac{dH_p}{dt} = \frac{T - \Delta T}{T} \cdot \frac{dh}{dt} = \frac{T - \Delta T}{T} \cdot \frac{(T_{tr} - D)V}{mg_0} \left[ 1 + \left( \frac{V}{g_0} \right) \left( \frac{dV}{dh} \right) \right]^{-1} \quad (3)$$

式中: $T$  表示大气温度; $\Delta T$  表示温差。

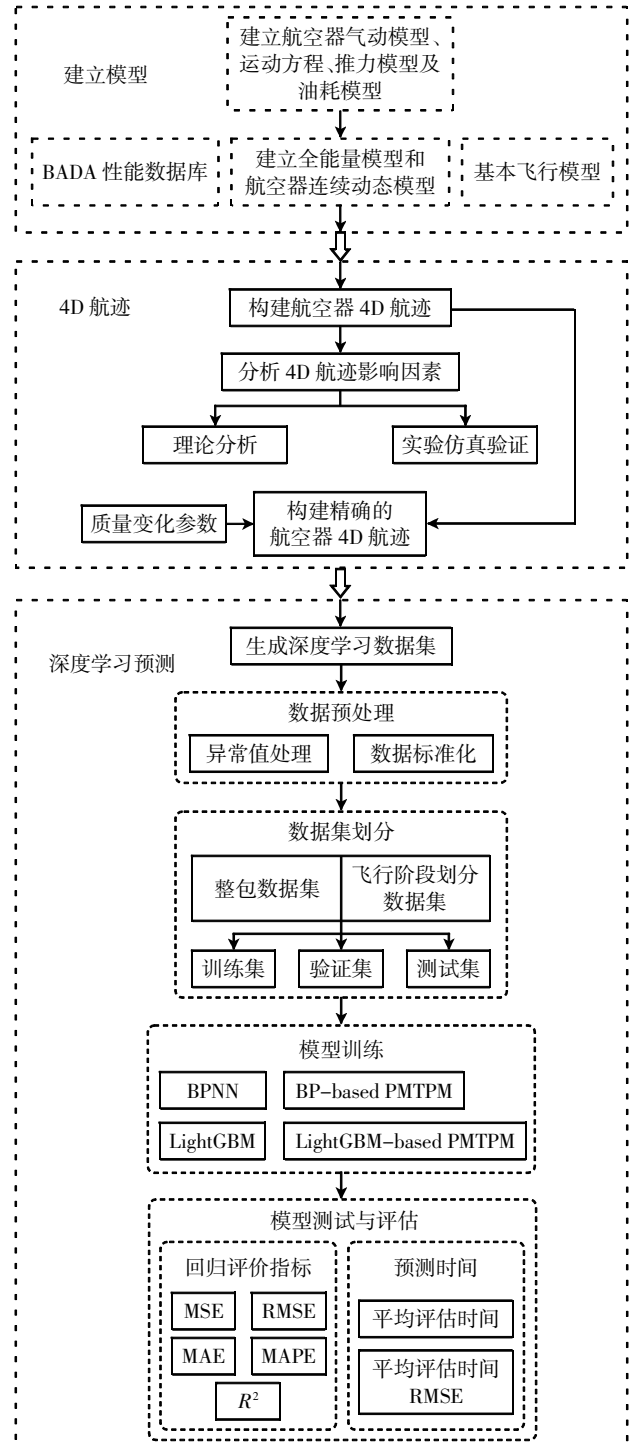


图 1 技术路线图

Fig.1 Technology roadmap

### 1.2.2 气动及推力模型

航空器在运行过程中受到空气动力、重力以及推力的影响,基于牛顿运动定律建模后可以转化成对航空器速度和 ROCD 的影响。

航空器阻力  $D$  的计算公式为

$$D = \frac{\rho \cdot V^2 \cdot S \cdot C_D}{2} \quad (4)$$

式中: $\rho$  为航空器外界环境大气密度; $S$  为机翼参考面积; $C_D$  为阻力系数,其取值与航空器构型和升力系数有关。

涡扇式发动机的最大爬升推力  $T_{hr1}$  的计算公式为

$$T_{hr1} = C_{TC,1} \cdot \left( 1 - \frac{H_p}{C_{TC,2}} + C_{TC,3} \cdot H_p^2 \right) \cdot (1 - C_{TC,5} \cdot \Delta T_{eff}) \quad (5)$$

式中: $C_{TC,1}$ 、 $C_{TC,2}$ 、 $C_{TC,3}$ 、 $C_{TC,5}$  分别为第一最大爬升推力系数、第二最大爬升推力系数、第三最大爬升推力系数、第二推力温度系数; $\Delta T_{eff} = \Delta T - C_{TC,4}$ ,  $C_{TC,4}$  为第一推力温度系数。

最大巡航推力  $T_{hr2}$  的计算公式为

$$T_{hr2} = C_{TCr} \cdot T_{hr1} \quad (6)$$

式中, $C_{TCr}$  为最大巡航推力系数。

最大下降推力  $T_{hr,des}$  的计算公式为

$$T_{hr,des} = \begin{cases} C_{Tdes,high} \cdot T_{hr1} & H_p \geq H_{p,des} \\ C_{Tdes,low} \cdot T_{hr1} & H_{max,AP} < H_p < H_{p,des} \\ C_{Tdes,app} \cdot T_{hr1} & H_{max,LD} < H_p < H_{max,AP} \\ C_{Tdes,ld} \cdot T_{hr1} & H_p \leq H_{max,LD} \end{cases} \quad (7)$$

式中: $C_{Tdes,high}$ 、 $C_{Tdes,low}$ 、 $C_{Tdes,app}$ 、 $C_{Tdes,ld}$  分别为高空下降推力系数、低空下降推力系数、进近下降推力系数、降落下下降推力系数; $H_{p,des}$  为计算下降推力的过渡高度; $H_{max,AP}$ 、 $H_{max,LD}$  分别为最大进近高度阈值和最大着陆高度阈值。

### 1.2.3 油耗模型

在航迹预测中,燃油消耗是航空器质量变化的根本原因。燃油消耗率即单位推力的燃料消耗,是真空速的函数,其计算公式为

$$S_{FC} = C_{f1} \cdot \left( 1 + \frac{V}{C_{f2}} \right) \quad (8)$$

式中, $C_{f1}$ 、 $C_{f2}$  分别为第一推力和第二推力的燃油消耗率系数。

额定燃油流量  $f_{nom}$  的计算公式为

$$f_{nom} = S_{FC} \cdot T_{hr} \quad (9)$$

## 1.3 预测模型

本文基于 BADA 并结合飞行计划,建立了航空器的 4D 航迹。由于航空器自身性能及其他外部条件的影响,航空器在运动过程中遵循一定的规律,而不是随机运动的。因此,航空器的位置、高度、受力等参数与其实时质量之间存在函数关系。然而,具体的函数

形式难以确定,因此,将航空器实时质量的预测视为回归问题,可以采用深度学习模型进行求解。

### 1.3.1 BPNN

BPNN 是一种多层前馈神经网络<sup>[22]</sup>,该算法主要包括前向传播和反向传播,常用于分类或回归等任务。BPNN 可以通过反向传播算法自动调整权重和偏置,从而学习复杂的非线性映射关系,被广泛应用于图像或语音识别、金融预测等领域。因此,其具有良好的泛化能力和自适应能力。然而,BPNN 训练过程通常需要大量计算资源和时间,容易陷入局部最优解,并且对大量高质量训练数据的依赖性高。因此,模型的性能对超参数敏感,需要通过经验或试验进行调节,过程较为繁琐。由于网络的复杂性,BPNN 的内部机制和决策过程也难以解释。

### 1.3.2 LightGBM 算法

LightGBM 算法是微软亚洲研究院提出的一种快速、高效的梯度提升决策树 (GBDT, gradient boosting decision tree) 模型优化框架<sup>[23]</sup>。其核心算法是基于构建决策树,通过每次迭代构建新的树以最小化目标函数。GBDT 的目标是通过不断迭代构建新的决策树,逐步减少预测误差。其核心思想是通过前向分布算法最小化损失函数,其计算公式为

$$L^{(l)} = \sum_{i=1}^n l(y_i, F_{k-1}(x_i) + \eta f_k(x_i)) \quad (10)$$

式中: $L^{(l)}$  为第  $k$  轮的目标函数; $l$  为损失函数; $y_i$  为第  $i$  个样本的真实值; $n$  为样本数量; $F_{k-1}(x_i)$  为模型在第  $k-1$  轮的预测值; $f_k(x_i)$  为第  $k$  轮新训练的决策树的预测值; $\eta$  为学习率,控制每棵树对最终模型的贡献。

LightGBM 相较于传统的 GBDT 模型,使用了 2 项新技术,分别是梯度单边采样技术和独立特征合并技术。梯度单边采样技术的核心思想是在计算信息增益时,通过对梯度进行有策略的采样来减少计算量,同时保持模型性能。独立特征合并技术的主要目标是通过互斥的稀疏特征进行合并以减少特征数量,从而降低模型的复杂度和训练时间。

### 1.3.3 LightGBM-based PMTPM

为了解决数据的差异性以及模型的泛化性等问题,本文使用了 LightGBM-based PMTPM 和 BP-based PMTPM。其主要思想是将数据集按照隐含特征分成几类,并针对每一类数据分别训练独立的 LightGBM 模型或 BPNN。这 2 种分阶段多模态航迹预测方法可以结合航空机载设备计算的数据进行智能分析,通过观察航空器运行状态参数的变化,同时结合飞行管理系统中的飞行计划剖面,识别出当前时刻下航空器所处

的飞行阶段。不同飞行阶段的航空器动力学和运动学模型物理运算逻辑有所不同,但同一飞行阶段的航空器飞行特性较为集中和明显,数据具有更强的相似性。根据飞行阶段对数据进行分类,对每一类数据使用同一种深度学习模型,确保模型统一、流程简化,称为多模态方法。同时相较整包训练,分阶段多模态方法超参数量级降低,显著提高了运算效率,在进行预测时只需将飞行状态参数输入模型中即可得到结果,训练过程在地面设备上完成,对航空电子设备硬件要求不高。其可以实现对飞行数据的智能划分,针对不同飞行阶段训练不同的模型,实现飞行数据的精确化处理,提高航迹预测的准确性。

该类方法有以下 6 个显著优点。

(1)更好的模型拟合能力。对于每一个独立的飞行阶段均有一套对应的计算逻辑,因此,各飞行阶段数据蕴含大量的隐含特征。从提取到的隐含特征制定分类规则并进行数据划分,每个模型只需专注于处理一类特定数据。这减少了不同类别数据之间的特征干扰,使得模型能够更好地拟合各自类别的数据特性,提高了模型的整体表现。

(2)减少模型复杂性。当数据集被分成多个类别后,每个子集的数据维度明显降低,因此,使用的模型算法复杂度也可以降低。这使得训练过程更为高效,

也能减少过拟合的风险。

(3)提升模型泛化能力。由于每个模型专注于不同类型的数据,能够更好地捕捉这些数据的内在规律,从而在面对新数据时具有更好的泛化能力。

(4)灵活性强。这种方法允许对不同类别的数据使用不同的模型结构或超参数设置。这意味着可以根据每类数据的特点,定制最合适的模型架构和训练策略,进一步提高模型的性能。

(5)提高训练效率。由于每个模型只处理一部分数据,训练时间可以显著缩短。在处理大规模数据集时,将数据划分为多个子集后进行并行训练,还能利用多核处理器或分布式计算资源,提高训练效率。

(6)更好的解释性。将数据分类后独立训练的方式使得每个模型的输出更具针对性,可以更容易地分析和解释每一类数据的模型决策过程。这对理解模型如何对不同类别的数据做出预测非常有帮助。

## 2 实验

### 2.1 4D 航迹预测步骤

基于航空器动力学模型和飞行计划,构建基于 BADA 的 4D 航迹预测模型。航迹预测的计算流程如图 2 所示。

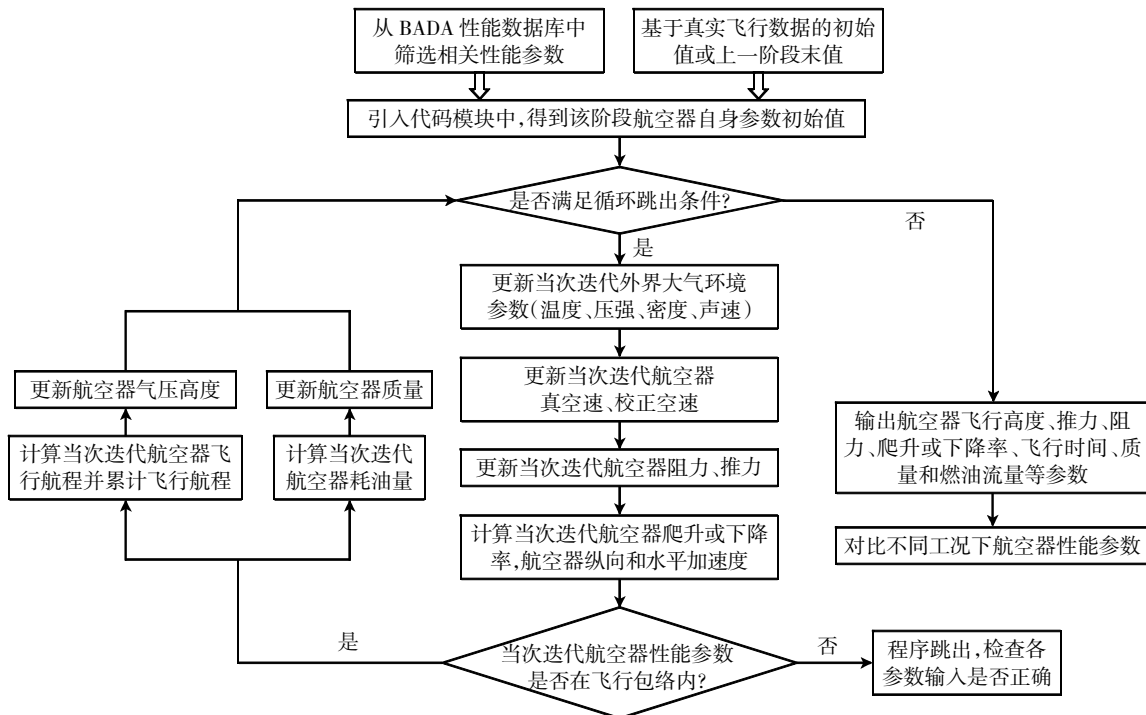


图 2 4D 航迹计算流程

Fig.2 Calculation process for four-dimensional trajectory

### 2.2 仿真数据预处理

考虑到即使同一架航空器执行相同航班,其初始

质量也会有所不同。本文使用的数据集由前文构建的航空器 4D 航迹计算得到。本文参考 BADA 中该类机

型的状态参数, 设置初始质量在 60 000~80 000 kg 之间, 间隔值取 500 kg, 考虑不同的迭代步长, 进行笛卡尔积运算, 充分模拟航空器接近质量上限和下限的极

端情况。经过飞行包络判断, 去除不符合航空器真实运行的航迹后, 共得到 149 条航空器航迹。预处理后的实验数据共有 11 个特征, 示例如表 1 所示。

表 1 实验数据示例

Tab.1 Example of experimental data

温度/ K	气压高度/ m	真空速/ (m·s <sup>-1</sup> )	推力/ N	阻力/ N	推力-阻力/ N	ROCD/ (m·s <sup>-1</sup> )	燃油流量/ (kg·s <sup>-1</sup> )	距离/ m	飞行路径角/ (°)	质量/ kg
232.563 8	8 551.716 646	238.448 7	71 082.77	55 961.19	15 121.58	5.702 1	1.188 7	471 451.91	0.023 9	70 167.700 2
232.498 8	8 561.716 646	238.457 3	71 006.12	55 919.76	15 086.37	5.689 2	1.187 5	471 870.93	0.023 9	70 165.615 4
232.433 8	8 571.716 646	238.424 0	70 929.53	55 865.55	15 063.97	5.680 1	1.186 1	472 290.57	0.023 8	70 163.528 2
232.368 8	8 581.716 646	238.390 7	70 852.96	55 811.46	15 041.50	5.671 0	1.184 8	472 710.82	0.023 8	70 161.439 9
232.303 8	8 591.716 646	238.357 3	70 776.44	55 757.46	15 018.97	5.661 9	1.183 5	473 131.69	0.023 8	70 159.350 7
232.563 8	8 551.716 646	238.324 0	70 699.95	55 703.57	14 996.38	5.652 7	1.182 2	473 553.18	0.023 7	70 157.260 4

航迹数据中的特征, 如温度、气压高度和真空速, 由于量纲的不同, 数值之间存在显著差异。为了减小不同量纲对神经网络预测的影响, 并确保输入模型的数据是同一量纲, 本文对数据进行了归一化处理, 将其缩放至 0~1 之间。采用的归一化方法为离差标准化, 其计算公式为

$$X^* = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (11)$$

式中:  $X$  表示原始特征数据;  $X^*$  表示归一化之后的数据。

### 2.3 仿真数据预处理

在进行实验仿真之前, 需要对数据集进行划分。数据集被分为训练集、验证集和测试集, 比例分别为 80%、10%和 10%。首先, 本文使用训练集数据分别对实验模型进行训练, 通过观察 MSE 函数的变化趋势, 确定初始主要参数。然后, 利用验证集对模型的超参数加以校正。最后, 使用测试集结果对模型进行评估。结果显示, 训练集包含 2 089 436 条数据, 而验证集和测试集均包含 261 444 条数据。

### 2.4 实验模型

实验模型采用 BPNN、BP-based PMTPM、LightGBM 模型和 LightGBM-based PMTPM。具体的实验步骤如

图 3 所示。在模型训练完成后, 使用回归模型常用的评价指标对结果进行评估。

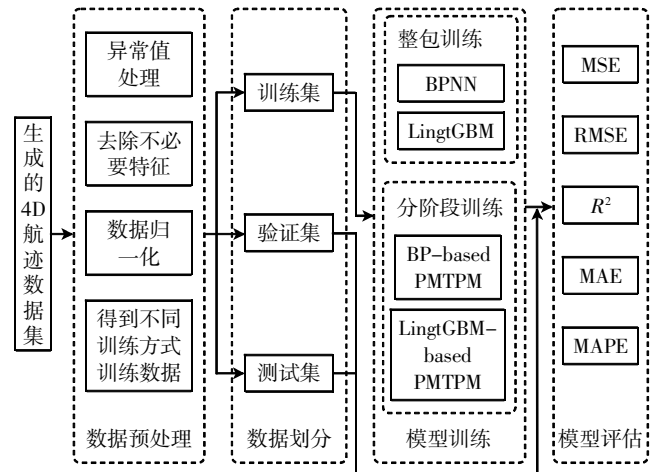


图 3 实验步骤

Fig.3 Experimental steps

为了更好地体现出模型预测值与真实值之间的误差, 本研究在 4 种模型训练和预测过程中均采取了不同的超参数设置, 具体信息如表 2 和表 3 所示。针对 LightGBM 模型和 LightGBM-based PMTPM, 本文利用 Optuna 框架进行超参数寻优。此外, 4 种模型都设置了早停机机制, 防止模型出现过拟合的情况。

表 2 BPNN 超参数设置

Tab.2 Hyperparameter settings of BPNN

基于 BPNN 的深度学习模型	隐藏层层数	隐藏层神经元数	批尺寸	学习率	训练周期	损失函数	激活函数	优化器	Patience	Min_delta
BPNN	3	(64, 128, 64)	256	0.001	100	MSE	relu	Adam	40	2
BP-based PMTPM	3	(32, 64, 32)	256	0.001	100	MSE	relu	Adam	40	2

表 3 LightGBM 超参数设置

Tab.3 Hyperparameter settings of LightGBM

基于 LightGBM 的深度学习模型	决策树数量	决策树最大深度	最大叶子节点数	学习率	寻优次数	早停轮次
LightGBM	4 067	12	2 <sup>12</sup> -1	0.322 8	50	500
LightGBM-based PMTPM	[1 883, 1 509, 1 678, 1 499, 1 784, 2 032 1 619]	[7, 28, 28, 20, 9, 21, 21]	[2 <sup>7</sup> -1, 2 <sup>28</sup> -1, 2 <sup>20</sup> -1, 2 <sup>20</sup> -1, 2 <sup>9</sup> -1, 2 <sup>21</sup> -1, 2 <sup>21</sup> -1]	[0.322 0, 0.226 5, 0.494 3, 0.449 8, 0.493 3, 0.418 5, 0.476 2]	10	500

## 2.5 实验评价指标

本文采用 MSE、RMSE、 $R^2$ 、MAE 和 MAPE 作为评价标准。其中:MSE 可以反映模型预测值的平均偏离程度;RMSE 是 MSE 的平方根,单位与目标变量一致,便于理解; $R^2$  表示模型对数据方差的解释能力,越接近 1 越好;MAE 可以反映预测误差的平均水平;MAPE 相比于 MAE,提供了一个标准化的误差度量。5 个评价标准计算公式分别表示为

$$e_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

$$e_{\text{RMSE}} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (15)$$

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (16)$$

式中, $y_i$ 、 $\hat{y}_i$ 、 $\bar{y}$  分别表示航空器在第  $i$  个航迹点的真实质量、预测质量和在  $n$  个航迹点的平均质量。

## 3 结果与讨论

### 3.1 4D 航迹预测

本文以 A321 为例,进行了基于飞行计划的 4D 航迹预测。首先,通过浏览 BADA 数据库,设定航空器的起始质量为 72 t,假定该空域大气条件为国际标准大气、静风、修正海压为 1 013.2 hPa。考虑到航空器在爬升过程中的动力学构型较为复杂,以及在巡航过程中可能面临的突发状况。因此,本文在 BADA 提供的速度推荐手册指导下,从巡航阶段典型飞行计划剖面设置的 4 个阶段扩展为 7 个阶段,并在迭代过程中考虑到航空器在运行过程中由于燃料消耗导致的质量变化:

(1)航空器结束爬升过程,在 28 000 ft (1 ft = 0.304 8 m) 转为巡航,以 0.72 的恒定马赫数飞行 300 km;

(2)航空器在维持高度不变的情况下,从马赫数 0.72 加速至马赫数 0.78;

(3)航空器以马赫数 0.78 平直飞行 15 min;

(4)航空器完成一次阶梯爬升,爬升高度为 2 000 ft,采用等马赫数等爬升推力等级爬升;

(5)航空器在维持高度不变的情况下,以马赫数

0.78 飞行至总航程达到 800 km;

(6)航空器在维持高度不变的情况下,从马赫数 0.78 减速至马赫数 0.74;

(7)航空器以马赫数 0.78 下降至转换高度,再以等表速 300 kt (1 kt = 1.852 km/h) 下降至 20 000 ft。

基于上述飞行阶段,模型求解得到航空器的真空速、气压高度和质量随时间变化如图 4 所示。图 4 中用点区分不同的飞行阶段。从图 4 可以看出,速度剖面和垂直剖面与飞行计划的吻合度较高。从质量-时间图可以看出,经过约 63 min 的飞行后,航空器的质量从 72 000 kg 降至 69 000 kg,燃油消耗占航空器总质量的 4.37%。因此,在 4D 航迹预测过程中,航空器质量变化不容忽视。




图4 航空器真空速-时间、气压高度-时间、质量-时间图

Fig.4 True airspeed-time, pressure altitude-time and mass-time profiles of the aircraft

### 3.2 模型对比结果

为了充分验证本文所采用的 LightGBM 模型的优越性和有效性,本文首先对比分析了 BPNN 与 LightGBM 模型的预测效果。使用相同的数据集输入到这 2 种模型中,对测试集的整体评估指标对比如表 4 所示。

通过表 4 可以看出,LightGBM 相比 BPNN,其 RMSE 下降了 52.52%,所有性能指标均好于 BPNN,两者决定系数也都极其接近 1,这说明 LightGBM 模型对航空

表 4 实验模型评价指标对比

Tab.4 Comparison of evaluation metrics for experimental models

预测模型	MSE	RMSE	$R^2$	MAE	MAPE/%
BPNN	1 380.198 0	37.150 15	0.999 991	28.504 62	0.042 1
LightGBM	311.167 6	17.639 94	0.999 996	4.583 78	0.006 8

器运行过程中的实时质量预测更为准确。但此时尚未考虑飞行阶段划分对模型的精细化影响,仍需讨论BP-based PMTPM 和 LightGBM-based PMTPM 的预测效果。同时 BPNN 和 LightGBM 也可以对每个飞行阶段进行具体预测,4 种模型的评估结果如表5 所示。

表 5 模型评估结果对比

Tab.5 Comparison of model evaluation results

预测模型	阶段	MSE	RMSE	$R^2$	MAE	MAPE/%
BPNN	阶段 1	761.825 400	27.601 180	0.999 978	24.589 100	0.035 6
	阶段 2	8 153.083 000	90.294 430	0.999 760	69.144 300	0.101 5
	阶段 3	1 168.487 000	34.183 150	0.999 965	29.908 000	0.044 0
	阶段 4	21 025.130 000	145.000 400	0.999 353	124.071 000	0.184 5
	阶段 5	704.634 500	26.544 950	0.999 979	22.991 900	0.034 7
	阶段 6	10 278.500 000	101.383 000	0.999 687	81.565 240	0.121 2
	阶段 7	2 245.266 000	47.384 240	0.999 932	37.147 110	0.055 7
BP-based PMTPM	阶段 1	193.096 700	13.895 930	0.999 994	11.998 090	0.017 3
	阶段 2	6 393.529 000	79.959 550	0.999 812	60.302 150	0.088 2
	阶段 3	173.639 400	13.177 230	0.999 995	11.351 440	0.016 7
	阶段 4	83 227.24 000	288.491 300	0.997 439	214.478 200	0.318 6
	阶段 5	637.940 200	25.257 480	0.999 981	21.867 350	0.032 6
	阶段 6	6 683.238 000	81.751 070	0.999 796	67.978 930	0.101 7
	阶段 7	1 009.264 000	31.768 920	0.999 969	23.552 550	0.035 2
LightGBM	阶段 1	36.345 190	6.028 697	0.999 999	3.240 534	0.004 7
	阶段 2	2 593.526 000	50.926 680	0.999 924	19.230 910	0.028 2
	阶段 3	22.333 310	4.725 813	0.999 999	3.497 312	0.005 1
	阶段 4	10 412.840 000	102.043 300	0.999 680	56.340 170	0.083 7
	阶段 5	17.505 130	4.183 913	0.999 999	3.342 364	0.005 0
	阶段 6	5 622.131 000	74.980 870	0.999 829	31.767 210	0.047 2
	阶段 7	1 068.291 000	32.684 720	0.999 968	4.455 573	0.007 0
LightGBM-based PMTPM	阶段 1	23.841 056	4.882 730	0.999 999	3.286 275	0.004 7
	阶段 2	4 822.943 696	69.447 417	0.999 858	10.559 308	0.015 1
	阶段 3	6.345 712	2.519 070	1.000 000	1.390 674	0.002 0
	阶段 4	4 227.447 714	65.018 826	0.999 870	36.650 648	0.054 2
	阶段 5	11.710 182	3.422 014	1.000 000	2.256 245	0.003 3
	阶段 6	6 228.896 858	78.923 361	0.999 810	15.229 043	0.023 1
	阶段 7	658.538 133	25.661 998	0.999 980	3.741 936	0.005 9

通过表 5 可以看出,首先将 BPNN 与 LightGBM 进行对比,观察到 LightGBM 模型在每个飞行阶段的评估结果都显著优于 BPNN,表明 LightGBM 具有更高的预测准确性,与表 4 得到的结论一致。BP-based PMTPM 相较于 BPNN,除阶段 4 以外,其RMSE 分别降低了49.65%、11.45%、61.45%、4.85%、19.36%、32.95%; LightGBM-based PMTPM 相较于LightGBM,除阶段 2 和阶段 6 以外,其 RMSE 分别降低了 19.01%、46.70%、36.28%、18.21%、21.49%,这证明了按飞行阶段分阶段

训练模型的有效性。同时观察表 2 和表 3 可以得知,基于分阶段训练的模型使用的超参数量级下降,进一步说明了分阶段训练的优势。

与此同时,相较于 BP-based PMTPM,LightGBM-based PMTPM 在每个飞行阶段都表现出更优的预测性能,RMSE 分别降低了 64.86%、13.15%、80.88%、77.46%、86.45%、3.46%、19.22%。这说明本文提出的 LightGBM-Based PMTPM 在处理航迹预测这一复杂的非线性回归问题上具有更强的能力。

针对阶段 2、阶段 4 和阶段 6 在某些模型中表现不佳的原因,本文认为,这 3 个阶段的持续时间相对于整个飞行过程较短。数据集分析显示,这些阶段的平均持续时间均为 100 s,导致系统无法记录足够的数据量,从而导致数据集的丰富度不足,进而影响了这些阶段在分阶段模型训练中的表现。

基于上述分析,可以得出以下结论。

(1)在每个飞行阶段,LightGBM 模型相较于 BPNN 模型均表现更优,MSE、RMSE、MAE 均显著降低,展示出较强的非线性回归能力。

(2)分阶段多模态航迹预测模型相较于传统的将数据全部打包进行预测的模型,具有更高的预测精度。按飞行阶段分阶段训练模型,可以更好地捕捉每个阶段的特定特征,提高整体预测性能。

本文将 4 类模型的训练和评估时间进行对比,使用蒙特卡洛法随机采样未来 30 min 的航迹,记录每次预测所需的时间,结果如表 6 所示。

表 6 模型测试时间对比

Tab.6 Comparison of model testing time

预测模型	训练时间/ min	整体评估		独立评估	
		平均预测 时间/ms	预测时间 RMSE/ms	平均预测 时间/ms	预测时间 RMSE/ms
BPNN	63.80	1.138	0.200 7	0.380	0.053
BP-based PMTPM	165.52	—	—	1.111	0.063
LightGBM	8.84	565.490	7.590 0	566.150	7.297
LightGBM- based PMTPM	2.41	—	—	59.890	1.242

从表 6 可以看出,基于 LightGBM 的模型训练时间显著低于基于 BPNN 的模型。这主要归因于 LightGBM 的几个特点,包括基于直方图的算法、数据并行和特征并行的支持、高效的内存管理技术,以及对类别特征的支持,这些特点从算法原理和内存使用方面加快了模型的计算速度。然而,基于 BPNN 的模型评估时间短于基于 LightGBM 的模型,这主要是由于 BPNN 的架构特性。经过训练以确定最优权重和偏置后,BPNN 在对测试集进行预测时,只需将特征输入模型并进行计算,即可获得预测值。尽管如此,LightGBM-based PMTPM 的平均预测时间为 59.890 ms,这完全满足了现有导引系统和飞行机组对 4D 航迹预测实时性的要求。

## 4 结语

本文基于 SESAR 理念,对机载电子设备实现航迹

预测功能的实时性和准确性进行了探究。本文提出了 LightGBM-based PMTPM,考虑到同一飞行阶段利用 BADA 进行积分计算时航空器各项参数之间具有较强的关联性,提出将飞行数据按照飞行阶段进行划分,通过差异化提高了模型的计算效率和准确度。LightGBM-based PMTPM 相较于 BP-based PMTPM,RMSE 平均降低了 49.35%,LightGBM-based PMTPM 平均评估时间为 59.890 ms。本文可为未来国产大飞机机载电子设备运行航迹预测算法提供理论支持。

未来仍有许多具有重要意义的研究方向值得进一步探讨,尤其是模型的普适性研究。例如,可以引入更多类型的航空器,如涡桨式飞机,或考虑不同机型,如波音、中国商飞等公司的客机。此外,将天气因素作为重要影响变量纳入模型,可以进一步优化航迹预测的精度。后续研究将集中解决当前模型在特定阶段(如航空器在完成机动动作时)由于不同推力模式引起的预测误差问题。

## 参考文献:

- [1] PALLOTTINO L, FERON E M, BICCHI A. Conflict resolution problems for air traffic management systems solved with mixed integer programming[J]. IEEE Transactions on Intelligent Transportation Systems, 2002, 3(1): 3-11.
- [2] ERZBERGER H, PAIELLI R A. Concept for next generation air traffic control system[J]. Air Traffic Control Quarterly, 2002, 10(4): 355-378.
- [3] EUROCONTROL EXPERIMENTAL CENTER. Phare highly interactive problem solver[R]. AT59-Phare Advanced Tools, 1994.
- [4] GUAN X M, LV R L, SUN L, et al. A study of 4D trajectory prediction based on machine deep learning[C]//2016 12th World Congress on Intelligent Control and Automation (WCICA), June 12-15, 2016, Guilin, China. IEEE, 2016: 24-27.
- [5] CHRISTODOULOU M A, KODAXAKIS S G. Automatic commercial aircraft-collision avoidance in free flight: the three-dimensional problem[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(2): 242-249.
- [6] LIU T, BAHL P, CHLAMTAC I. Mobility modeling, location tracking, and trajectory prediction in wireless ATM networks[J]. IEEE Journal on Selected Areas in Communications, 1998, 16(6): 922-936.
- [7] 吕波,王超.改进的扩展卡尔曼滤波在航空器 4D 航迹预测算法中的应用[J]. 计算机应用, 2021, 41(S1): 277-282.
- [8] RONG L X, JILKOV V P. Survey of maneuvering target tracking. Part I. Dynamic models[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1333-1364.
- [9] 倪育德,刘萍,马宇申.基于 ADS-B 意图信息的航迹预测改进算法[J]. 电讯技术, 2014, 54(2): 156-162.
- [10] LYMPEROPOULOS I, LYGEROS J, LECCHINI A. Model based aircraft trajectory prediction during takeoff[C]//AIAA Guidance, Navi-

(下转第 39 页)

准确性;②在实际指导层面,国内网络的连通性相较于国际网络更为紧密,在突发事件导致国内机场关闭时会对整体网络效率造成更大的影响;与中国连通的国外机场数量较多,但大量连通的航线与少量航点连接,多数国际航线若发生突发事件导致航线中断,难以选择可替代的航线。

根据研究结果提出以下建议:①增加一线城市的国际全货运航线比例,为突发事件下国际航线在国内进行中转提供预备方案;②加强国际全货运航线中的关键机场和航线抗风险能力,如在机场周边城市增设国际通航机场,或增加不同时刻的航班频率。

本研究在模型构建时未考虑航班频率不同产生的差异,也未考虑不同航线及机场在受到攻击时失效程度的差异,这些因素在未来的研究中可以被纳入考虑范围,以提高模型的合理性。

#### 参考文献:

[1] 王兴隆,张淑婷. 航空网络影响力节点识别与鲁棒性分析[J]. 科学技术与工程, 2019, 19(8): 297-302.

[2] 王世锦,苏思雨,李海云,等. 基于 PCNC 的航路网络拓扑结构鲁棒性优化[J]. 南京航空航天大学学报, 2019, 51(6): 756-762.

[3] DU W B, ZHOU X L, LORDAN O, et al. Analysis of the Chinese airline network as multi-layer networks[J]. *Transportation Research Part E: Logistics and Transportation Review*, 2016, 89: 108-116.

[4] YAO H G, XIAO H H, WEI W. Study on the hierarchical structure of the "Belt and Road" aviation network based on K-core analysis[J]. *Discrete Dynamics in Nature and Society*, 2022, 2022(1): 2349523.

[5] 吴媛媛,刘向军. 考虑级联失效影响的复杂网络关键节点识别[J]. 计算机工程与设计, 2021, 42(4): 920-926.

[6] 王世瑞,吴薇薇. 基于航线网络结构特征的鲁棒性研究[J]. 哈尔滨商业大学学报(自然科学版), 2022, 38(6): 714-722.

[7] QIAN B X, ZHANG N. Topology and robustness of weighted air transport networks in multi-airport region[J]. *Sustainability*, 2022, 14(11): 6832.

[8] 程 擎,王德超,李怡恒. 新冠疫情影响下航线网络时序鲁棒性分析[J]. 计算机与数字工程, 2022, 50(12): 2710-2714, 2814.

[9] YANG R S, SUN W, LE M L, et al. The Chinese aviation network: an empirical temporal analysis on its structural properties and robustness[J]. *Applied Sciences*, 2023, 13(21): 11627.

[10] 赖 强,马 鑫,张宏昊,等. 航空网络结构鲁棒性分析[J]. 华中科技大学学报(自然科学版), 2024, 52(1): 106-111.

[11] 冯 霞,贾宏臻. 考虑节点失效和边失效的航空网络鲁棒性[J]. 北京交通大学学报, 2021, 45(5): 84-92.

[12] 孙军艳,牛亚儒,吴冰莹,等. 西安公共交通系统的网络特性和鲁棒性分析[J]. 华侨大学学报(自然科学版), 2019, 40(2): 148-155.

[13] 张 锦,张哲睿,洪治潮,等. 新冠疫情背景下航空物流网络的鲁棒性优化[J]. 北京航空航天大学学报, 2023, 49(9): 2218-2226.

[14] 杨文东,邵佳佳,郑文娟. 不确定需求下航空公司国际联盟航线网络优化[J]. 中国民航大学学报, 2020, 38(3): 34-39.

[15] 徐 凤,朱金福,陈 丹. 东航空铁联运双层加权网络的关键节点识别与抗毁性分析[J]. 铁道运输与经济, 2023, 45(1): 93-100.

[16] 张光远,张 帆,刘泳博. 成渝地区城际铁路网络特性与脆弱性分析[J]. 铁道运输与经济, 2021, 43(7): 36-42.

[17] 彭 挺,张亚平,程绍武. 基于惩罚因子的层级式航线网络鲁棒性分析[J]. 交通运输系统工程与信息, 2016, 16(3): 187-193.

(责任编辑:明 月)

(上接第 9 页)

gation, and Control Conference and Exhibit, August 21-24, 2006, Keystone, Colorado. Reston, Virginia: AIAA, 2006: 6098.

[11] 谭 伟,陆百川,黄美灵. 神经网络结合遗传算法用于航迹预测[J]. 重庆交通大学学报(自然科学版), 2010, 29(1): 147-150.

[12] 冯 霞,孙琦琦,左海超. 基于 Informer 的客机长时 4D 航迹预测方法[J]. 交通信息与安全, 2023, 41(4): 111-121.

[13] WEITZ L A. Derivation of a point-mass aircraft model used for fast-time simulation[R]. USA: MITRE, 2015.

[14] 王 超,郭九霞,沈志鹏. 基于基本飞行模型的 4D 航迹预测方法[J]. 西南交通大学学报, 2009, 44(2): 295-300.

[15] 张军峰,蒋海行,武晓光,等. 基于 BADA 及航空器意图的四维航迹预测[J]. 西南交通大学学报, 2014, 49(3): 553-558.

[16] SCHULTZ C, THIPPHAVONG D, ERZBERGER H, et al. Adaptive trajectory prediction algorithm for climbing flights[C]//AIAA Guidance, Navigation, and Control Conference, August 13-16, 2012, Minneapolis, Minnesota. Reston, Virginia: AIAA, 2012: 4931.

[17] ALLIGIER R, GIANAZZA D, DURAND N. Learning the aircraft mass and thrust to improve the ground-based trajectory prediction of climbing flights[J]. *Transportation Research Part C: Emerging Technologies*,

2013, 36: 45-60.

[18] CHATTERJI G B. Fuel burn estimation using real track data[C]//11th AIAA Aviation Technology, Integration, and Operations (ATIO) Conference, September 20-22, 2011, Virginia Beach, VA. Reston, Virginia: AIAA, 2011: 6881.

[19] THIPPHAVONG D P, SCHULTZ C A, LEE A, et al. Adaptive algorithm to improve trajectory prediction accuracy of climbing aircraft[J]. *Journal of Guidance, Control, and Dynamics*, 2012, 36(1): 15-24.

[20] EUROPEAN EXPERIMENTAL CENTER. User manual for the base of aircraft data (BADA): revision 3.12[R]. Brétigny: EEC, 2014.

[21] RENTEUX J L. Aircraft modelling standards for future ATC systems: Eurocontrol division E1 Document[R]. Brussels: Eurocontrol, 1987.

[22] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323: 533-536.

[23] KE G L, MENG Q, FINLEY T, et al. LightGBM: a highly efficient gradient boosting decision tree[C]//Advances in Neural Information Processing Systems 30: Annual Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, CA, USA.

(责任编辑:刘雅婷)