

# 基于 CNN 和 SEIR 模型的航班延误扩散预测优化

朱代武, 蔡林均, 张瀚文

(中国民用航空飞行学院空中交通管理学院, 四川 广汉 618307)

**摘要:** 大面积航班延误引起的延误扩散现象对空中交通网络有显著影响。为更好地预测和控制延误扩散, 针对航班延误扩散的非线性复杂特性以及实时性、准确性难以兼顾的特点, 提出结合卷积神经网络(CNN)和传统流行病 SEIR(易感-潜伏-感染-恢复)模型的延误扩散预测模型。基于航班延误扩散传播机理和 SEIR 模型建立航班延误扩散动力学模型, 通过卷积神经网络对模型中的关键参数进行优化。利用 MATLAB 对优化后模型进行仿真。研究发现结合卷积神经网络模型后相比传统 SEIR 模型准确率提升了 17.95%。

**关键词:** 航班运行; 航班延误扩散; 航班链; SEIR(易感-潜伏-感染-恢复)模型; 卷积神经网络(CNN)

**中图分类号:** [U8] **文献标志码:** A **文章编号:** 1671-1807(2025)03-0065-06

随着民用航空业的快速发展, 航空公司为提高飞机使用率, 单架飞机一天内通常会连续到达多个过站机场, 执行多段航班<sup>[1]</sup>, 这导致如果上游航班延误会造成连锁反应, 影响多个航班。研究航班延误扩散, 可以在保证航班链不受影响的条件下提高航班运行效率, 减少延误扩散影响。目前采用航班延误波及树、Petri 网、马尔可夫模型、贝叶斯网络等传统方法和排队网络模型、支持数据挖掘等方法进行航班延误扩散问题研究分析<sup>[2-5]</sup>。同时传播动力学理论被逐渐用于航班延误扩散相关研究中。常用的建模方法包括基于传染病模型的 SEIR(易感-潜伏-感染-恢复模型, susceptible-exposed-infectious-recovered)模型<sup>[6-7]</sup>。然而传统的 SEIR 模型中参数通常是固定的, 使用模型时, 通常需要人工选择和提取特征, 因此传统 SEIR 模型无法动态适应空中交通系统中的变化。

近几年, 深度学习在图像处理、计算机视觉等领域取得较好的发展, 为空中交通管理邻域提供了新思路。目前采用粒子群优化算法优化 BP 神经网络来预测多机场终端区航班延误<sup>[8]</sup>。而卷积神经网络(convolutional neural network, CNN)可以通过多层卷积和池化, 分层次提取数据的局部模式和特征。利用此特点, 构建卷积神经网络-双向门控循环单元模型对终端区 4D 航迹进行高精度预测和冲突

检测<sup>[9]</sup>。卷积神经网络捕捉延误扩散方面同样有显著优势<sup>[10]</sup>。

## 1 问题描述

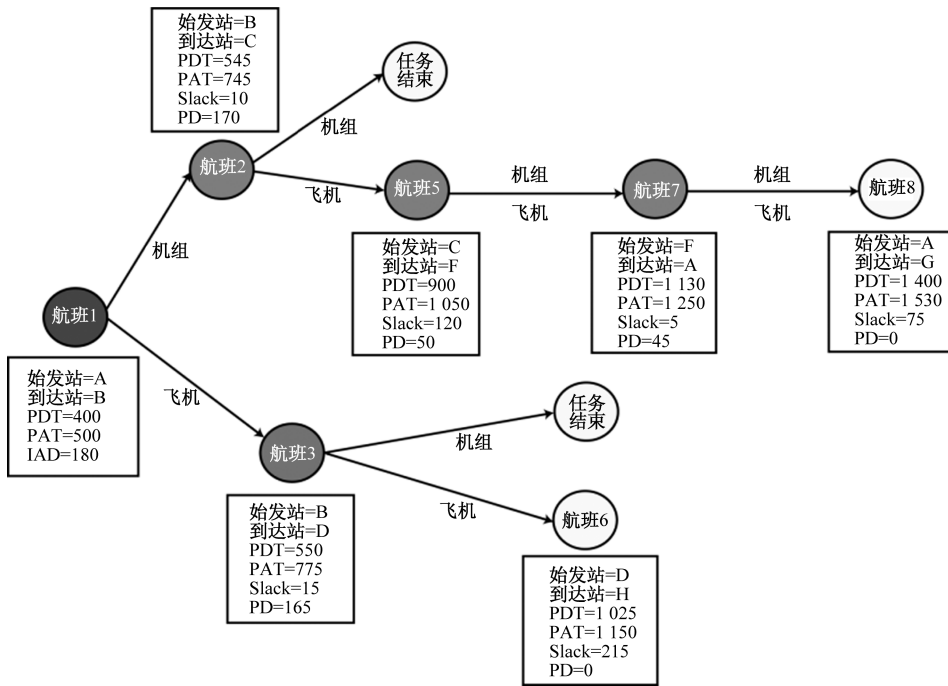
航班延误具有时空分布的特性, 当同一架飞机连续执行不同的航班任务时, 由于上游航班的延误而导致下游航班延误的情况常有发生。航班延误扩散会导致大面积航班延误, 如 2013 年云南昆明长水机场由于天气原因, 导致 440 个航班被取消, 约 7 500 名旅客滞留。图 1 给出了某航空公司航班延误扩散情况, 航班 1 由于天气原因导致初始延误 180 min, 影响了其后续多段航班的正常运行, 扩散导致下游航班延误 430 min。

为了提高对航班延误扩散的预测精度, 引入卷积神经网络(CNN)模型对传统 SEIR 模型进行优化。航班延误扩散问题具有明显的时空分布特征, 而 SEIR 模型本质上同样是一个连续的时间序列预测模型。CNN 在提取局部空间特征和处理二维数据方面具有优势, 能够很好地捕捉航班延误在时间和空间上的扩散规律<sup>[11]</sup>。因此 CNN 可以通过学习时间序列数据中的空间和时间特征, 使用卷积层自动提取航班延误数据中的时空特征, 将这些特征用于动态调整 SEIR 模型的传染率、潜伏期等关键参数, 从而提升模型的预测准确性。

**收稿日期:** 2024-08-25

**基金项目:** 民航局安全能力建设项目(14002600100015J013)

**作者简介:** 朱代武(1966—), 男, 四川广汉人, 硕士, 教授, 研究方向为飞行程序设计; 蔡林均(1997—), 女, 四川成都人, 硕士研究生, 研究方向为航空交通运输; 张瀚文(1999—), 男, 辽宁沈阳人, 硕士研究生, 研究方向为航空交通运输。



PDT 为计划的离港时间, min; PAT 为计划的到港时间, min; Slack 为过站松弛时间, min; PD 为波及延误, min

图 1 航班延误扩散情况

## 2 数据集构建

航班数据来源于美国交通运输统计局提供的航班数据。根据模型需求,选择 2015 年的航班数据共 1 936 758 条,并采用 MATLAB 构建所需数据集。航班数据中有部分异常值与空值,要先对原始航班数据集进行数据清洗。数据清洗工作主要包括处理原始航班数据和机场数据中的“无效值”和“缺失值”。根据美国联邦航空 (FAA)、中国民航总局 (CAAC) 的规定,如果延误大于 180 min 则相当于航班取消,所以这里的无效值包含延误时间大于 180 min 的情况<sup>[12]</sup>。同时保留数据关键特征列,如航班号、出发机场代码、到达机场代码、计划出发时间、实际出发时间。

根据航班延误扩散的时空特点,选择按照时间信息为主的强时序数据集构建方法,即按照航班号和时间排序,构造航班链数据。计算每个航班的延误时间,并根据航班的出发与到达情况建立链接,确定每个航班的延误状态。对每个航班链构造输入特征,如前序航班延误时间、当前航班的计划时间、机场的历史延误率等。标签则是每个航班的最终延误状态(即模型要预测的目标)。在构建和表示强时序数据集时,特别是针对航班延误预测中的航班链数据集,需要用集合的形式

来表示多维时序特征。这样的集合可以有效地捕捉航班之间的关联,特别是前后航班的延误对后续航班的影响。

在这种情况下,航班链数据集中每一个样本(集合元素)不仅仅是单个航班的信息,而是与该航班有关的多个时序特征的组合。构建时序性航班链数据集  $S$  表示为

$$S = \{s_1, s_2, \dots, s_n\} \quad (1)$$

式中:  $s_i$  为航班链数据集中的第  $i$  个样本;  $n$  为样本总数。样本  $s_i$  的集合表示为

$$\{(f_{i,1}, t_{i,1}), (f_{i,2}, t_{i,2}), \dots, (f_{i,m_i}, t_{i,m_i})\} \quad (2)$$

式中:  $f_{i,j}$  为第  $i$  个样本中的第  $j$  个特征(如前序航班的延误时间、目的地机场的平均延误率等);  $t_{i,j}$  为该特征对应的时间点或时序位置;  $m_i$  为样本  $s_i$  的特征数量。这样构造的时序数据集既能够捕捉到航班之间的关联关系,又能够保留每个航班自身的时序特征,便于模型在多维时序数据中学习和提取有用的信息。

## 3 模型构建

### 3.1 CNN-SEIR 模型的构建

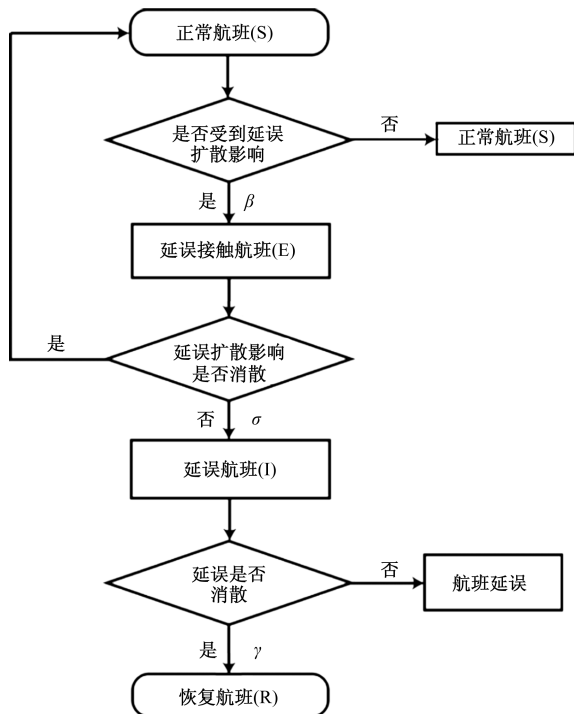
SEIR 模型是经典的流行病预测模型,用于描述传染病的传播过程。该模型将个体分为 4 类: S (易感者)、E (潜伏者)、I (感染者) 和 R (恢复者)。对

于航班延误的扩散,SEIR 模型可以用来描述航班延误的传播过程,将航班延误扩散看作是一种“传染病”,如果在“潜伏期”内消除延误扩散影响,则可以避免航班延误大面积扩散<sup>[7-8]</sup>。通过建立 SEIR 模型来分析航班延误的传播规律和影响因素。

基于 SEIR 模型的基本思想,在空中交通延误中依据航班是否出现延误,以及延误航班是否具有延误传播能力,将航班分为 4 类:正常航班 S、延误接触航班 E、延误航班 I、恢复航班 R。

正常航班 S 指未发生延误的航班,当航班链中上游航班出现延误,发生延误扩散时,可转化为延误航班 I。延误接触航班 E 是指上游航班已经发生延误时,该航班可能会受到影响,但暂时没有表现为延误,也无法传播延误状态,影响其他下游航班。当发生延误扩散则转变为延误航班 I,当延误影响消除,不再具备扩散性,则转变为正常航班 S。延误航班 I 受到延误扩散影响,航班发生延误,并且可以将延误状态扩散至航班链下游的航班。空中交通网络中航班相互关联,航班链中各航班状态转换如图 2 所示。

根据上文对航班延误扩散的分析可知,这些状态之间的转换过程可以用一组微分方程来描述。



$\beta$  为延误传播率,表示正常航班 S 转化为延误接触航班 E 的速率; $\sigma$  为潜伏期的倒数,表示延误接触航班 E 转化为延误航班 I 的速率; $\gamma$  为恢复率,表示延误航班 I 恢复为正常航 R 的速率

图 2 各航班状态转换情况

根据图 2 SEIR 传播动力学模型构建微分方程,具体方程为

$$\begin{cases} \frac{dS}{dt} = -\frac{\beta IS}{N} \\ \frac{dE}{dt} = \frac{\beta IS}{N} - \sigma E \\ \frac{dI}{dt} = \sigma E - \gamma I \\ \frac{dR}{dt} = \gamma I \\ N = S + E + I + R \\ \sigma = \frac{1}{\text{Slack} + \text{MCT}} \end{cases} \quad (3)$$

式中: $S$  为系统中正常航班的航班数量; $E$  为系统中延误接触航班的航班数量; $I$  为系统中延误航班的航班数量; $R$  为系统中恢复航班的航班数量; $t$  为时间,表示延误扩散过程的动态变化; $\text{MCT}$  为最小过站时间。

将其看作马可夫链假设后 1 min 的状态只与前 1 min 状态有关,故推出以下迭代方程:

$$\begin{cases} S_{n+1} = S_n - \frac{\beta I_n S_n}{N} \\ E_{n+1} = E_n - \frac{\beta I_n S_n}{N} - \sigma E_n \\ I_{n+1} = I_n + \sigma E_n - \gamma I_n \\ R_{n+1} = R_n + \gamma I_n \end{cases} \quad (4)$$

式中: $S_n$  为时刻  $n$  的正常航班数量; $E_n$  为时刻  $n$  的延误接触航班数量; $I_n$  为时刻  $n$  的延误航班数量; $R_n$  为时刻  $n$  的恢复航班数量; $n$  为时间步长,通常取 1 min,表示系统在离散时间上的更新间隔; $S_{n+1}$  为下 1 min 的正常航班数量; $E_{n+1}$  为下 1 min 的延误接触航班数量; $I_{n+1}$  为下 1 min 的延误航班数量; $R_{n+1}$  为下 1 min 的恢复航班数量。

为了提高 SEIR 模型在航班延误扩散预测中的表现,引入卷积神经网络(CNN)来优化模型的关键参数  $\sigma$ 、 $\beta$  和  $\gamma$ 。CNN 通过对大量历史航班数据进行学习,自动调整 SEIR 模型的参数,从而更加准确地预测航班延误的传播情况。

网络通过 4 个卷积结构块进行特征提取,每个结构块采用  $1 \times 1$  卷积作为初始层,用于通道整合或降维/升维。使用两个  $3 \times 3$  卷积核进一步提取航班延误数据中的时空特征,最后使用  $1 \times 1$  卷积进行融合。每个卷积层通过分组操作保证数据的独立性。卷积操作完成后,通过平均池化层对提取的特征进行筛选,最终将这些特征映射为 SEIR 模型的关键参数。经过全连接层后,数据被输入 SEIR 模型进行航班延误扩散预测。本文提出的 CNN-SEIR 网

络结构专门针对航班延误数据集进行优化,网络配置见表 1。网络结构示意图如图 3 所示。图 3 中  $x_1, x_2, x_3, x_4$  分别表示经过第 1 层、第 2 层、第 3 层、第 4 层卷积结构块后的特征输出。每一层的输出特征都保留了不同的时空信息,最后通过平均池化和全连接层映射到 SEIR 模型的关键参数,用于航班延误扩散预测。

其中输入层包含多个输入特征,如天气条件、机场容量、历史延误数据、航班过站时间等。设输入特征向量为  $\mathbf{X}$ 。卷积层通过卷积运算,提取输入数据的局部特征。这些特征包括航班延误的时间依赖性以及空间分布特性。卷积操作的输出  $\mathbf{C}^{(l)}$  可以表示为

$$\mathbf{C}^{(l)} = f(\mathbf{W}^l * \mathbf{X}^{(l-1)} + \mathbf{b}^{(l)}) \quad (5)$$

表 1 CNN-SEIR 模型的网络结构配置

网络层类型	输出矩阵大小	通道数	卷积核尺寸
输入层	128×128	3	—
卷积层	128×128	64	1×1
	128×128	64	3×3
	128×128	64	3×3
	128×128	64	1×1
最大池化层	64×64	64	2×2
全连接层	1×1	128	—
输出层	1×1	4	—




图 3 网络结构示意图

式中:  $\mathbf{W}^{(l)}$  为第  $l$  层的卷积核,  $l=1, 2, \dots, L$ ;  $\mathbf{b}^{(l)}$  为偏置;  $*$  表示卷积操作;  $f$  为激活函数。

经过若干卷积层和池化层后,最后通过全连接层将特征映射到目标输出,即 SEIR 模型的参数  $\sigma, \beta$  和  $\gamma$ , 可以表示为

$$\mathbf{Y} = \mathbf{W}^{(fc)} \mathbf{C}^{(L)} + \mathbf{b}^{(fc)} \quad (6)$$

式中:  $\mathbf{Y}$  为预测的  $\sigma, \beta$  和  $\gamma$ ;  $\mathbf{C}^{(L)}$  为最后一层卷积层的输出;  $\mathbf{W}^{(fc)}$  为全连接层的权重矩阵;  $\mathbf{b}^{(fc)}$  为全连接层的偏置向量。

### 3.2 网络反向传播

网络反向传播是训练神经网络的核心过程。这个过程是通过计算损失函数对网络参数的梯度,然后使用这些梯度来更新模型参数,从而最小化损失函数。通过定义损失函数来衡量 CNN 输出的参数与真实参数的差异。选择均方误差 MSE 作为损失函数,即

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^N (Y_i - Y_{\text{true},i})^2 \quad (7)$$

式中:  $Y_{\text{true}}$  为真实的  $\sigma, \beta$  和  $\gamma$ ;  $Y_i$  为模型预测的参数  $\sigma, \beta$  和  $\gamma$ 。

反向传播会计算损失函数对模型中每一个参数,包括卷积核、偏置、全连接层权重的梯度。使用梯度下降算法,根据计算结果使优化最小化损失函数,更新 CNN 模型的卷积核  $\mathbf{W}$  和偏置  $\mathbf{b}$ , 即

$$\begin{cases} \mathbf{W}^{(l)} \leftarrow \mathbf{W}^{(l)} - \eta \frac{\partial L}{\partial \mathbf{W}^{(l)}} \\ \mathbf{b}^{(l)} \leftarrow \mathbf{b}^{(l)} - \eta \frac{\partial L}{\partial \mathbf{b}^{(l)}} \end{cases} \quad (8)$$

式中:  $\eta$  为学习率,控制参数更新的步长大小;  $L$  为损失函数。

前向传播、损失计算和反向传播的步骤会在遍历整个训练数据集中重复。整个过程迭代进行,直到 CNN-SEIR 模型的参数被逐步调整至损失函数最小化,从而提高 CNN-SEIR 模型对航班延误传播的预测精度。这种优化过程能够在不依赖人为假设的情况下,对 SEIR 模型的各个参数进行实时调整,确保模型能够灵活适应多变的航班网络环境。

### 4 仿真及验证

通过 MATLAB R2017b 软件对 CNN 和 SEIR 融合模型求解。运行环境为 AMD A9-9420 RADEON R5, 5 CPU@3.00 GHz 处理器、4GB 内存、64 位 Windows10 操作系统。

根据来源于美国交通运输统计局 (bureau of transportation statistics, BTS) 提供的 2015 年实际航班数据。原始航班数据集中共有 1 936 758 条数

据,去除缺失值和无效值后,数据集中共有 1 247 486 条数据。经过时序航班链构造数据集处理后共有 1 189 774 条数据。其中 80% 作为训练集,20% 作为测试集,进行训练迭代后得到的其中部分预测参数和真实参数的对比(表 2)。最终优化后参数为  $\beta = 0.400 6$ ;  $\sigma = 0.316 1$ ;  $\gamma = 0.110 5$ 。得到结果传统 SEIR 模型均方误差为 0.115 3;优化后 SEIR 模型的均方误差为 0.094 6,优化后模型准确率提升 17.95%。

图 4 给出了传统 SEIR 模型仿真结果,假设  $\sigma = 0.22$ ,  $\beta = 0.3$ ,  $\gamma = 0.1$ 。面积延误开始时,延误开始传播,正常航班所占比值逐渐减小,延误接触航班所占比值先增大后减小,延误航班占比同样先增大后减小。且随着时间增加,不断有延误航班恢复正常,所以延误航班占比降低,恢复航班从 0 增加,此时空中交通网络逐渐恢复,最终所有延误航班都将会恢复正常。仿真结果和实际情况一致。

图 5 给出了优化后的 CNN-SEIR 模型仿真结果,可以看出传统模型仿真结果延误航班占比峰值出现在 50 min 附近,而优化后模型仿真结果中延误航班占比峰值出现在 40 min 附近。说明延误预测优化后能够提前做出调度提高效率。延误航班占比

表 2 预测参数与真实参数对比

预测参数			真实参数		
$\sigma$	$\beta$	$\gamma$	$\sigma$	$\beta$	$\gamma$
0.222 3	0.521 9	0.063 3	0.364 6	0.554 7	0.076 6
0.213 4	0.563 3	0.130 8	0.242 2	0.408 0	0.114 0
0.279 2	0.596 9	0.071 0	0.264 3	0.511 7	0.073 2
0.286 4	0.583 1	0.084 3	0.319 1	0.319 1	0.077 8
0.279 1	0.415 4	0.415 4	0.228 5	0.465 4	0.103 6
0.283 6	0.482 8	0.098 3	0.325 1	0.519 0	0.089 2
0.285 1	0.487 5	0.100 8	0.294 2	0.509 5	0.101 3




图 4 传统 SEIR 模型仿真结果

由传统模型仿真结果的 0.2 提升优化后模型的 0.35,则说明结合 CNN 后的模型对航班延误有了更加准确的判断,精度更高,峰值判断更准确。图 6 给出传统 SEIR 模型与优化后 CNN-SEIR 模型关于延误航班占比时间变化情况的对比,可以更直观地看到优化后的 CNN-SEIR 模型判断更准确。




图 5 优化后 CNN-SEIR 模型仿真结果




图 6 传统 SEIR 模型与优化后 CNN-SEIR 模型对比

### 5 结论

传统的传染病模型 SEIR 模型可以将复杂的航班扩散过程简化为易感、潜伏、感染、恢复 4 个状态,并且通过定义不同状态之间的转移率模拟延误在航班网络中的传播,使航班延误扩散的过程更加直观和清晰。但是 SEIR 模型中的参数通常是固定的,在使用时需要根据经验或历史数据手动选择、提取特征,这导致 SEIR 模型缺乏自动化的特征提取能力,无法反映航班延误扩散过程中的动态变化和复杂性。针对 SEIR 模型用于航班延误扩散的不足,将卷积神经网络与传统 SEIR 模型结合。提出

一种基于 CNN 和 SEIR 算法模型融合的航班延误扩散预测优化模型,利用 CNN 的特征提取能力,通过对大量历史航班数据进行学习来实时优化 SEIR 模型中的关键参数  $\sigma$ 、 $\beta$  和  $\gamma$ , 得出以下结论。

(1)利用融合算法模型结合真实航班数据集进行试验仿真,仿真结果证明融合前的传统 SEIR 模型均方误差为 0.115 3;融合后 SEIR 模型的均方误差为 0.094 6,优化后模型准确率提升 17.95%。

(2)仿真结果表明基于 CNN 和 SEIR 模型融合的航班延误扩散预测优化模型预测精度显著提升,证明模型能够更好地适应航班延误扩散的复杂时空特性,能有效解决现实中航班延误扩散的问题。

### 参考文献

- [1] 曹卫东, 梁陈. 基于 MA-BiLSTM 的多时间窗航班过站时间估计方法[J]. 陕西科技大学学报, 2022, 40(4): 183-190.
- [2] 梁陈. 基于贝叶斯深度学习的多时间窗航班过站时间动态估计[D]. 天津: 中国民航大学, 2022.
- [3] 高强, 周覃, 陈欣. 基于波及延误的航班过站松弛时间重分配[J]. 华南理工大学学报(自然科学版), 2019(10): 151-156.
- [4] 丁建立, 陈坦坦, 刘玉洁. 有色-时间 Petri 网航班延误模型与波及分析[J]. 计算机集成制造系统, 2008, 14(12): 2334-2340.
- [5] 周覃. 基于延误控制的航班计划调整[D]. 南京: 南京航空航天大学, 2020.
- [6] 李明捷, 黄欣宁, 吕晨辉, 等. 基于排队网络模型的机场航班延误预测[J]. 科学技术与工程, 2023, 23(27): 11886-11891.
- [7] 张佳. 大面积航班延误的传播及控制研究[D]. 天津: 中国民航大学, 2021.
- [8] 张兆宁, 张佳. 基于 SEIR 模型的大面积航班延误传播[J]. 科学技术与工程, 2020, 20(8): 3356-3361.
- [9] 张兆宁, 查子奇. 基于多机场终端区交通态势的航班延误预测[J]. 科学技术与工程, 2024, 24(12): 5220-5226.
- [10] 张飞桥, 张亦驰, 严皓. 基于改进卷积网络的终端区 4D 航迹预测与冲突检测[J]. 科学技术与工程, 2024, 24(5): 2150-2157.
- [11] 姜雨, 陈名扬, 袁琪, 等. 基于时空图卷积神经网络的离港航班延误预测[J]. 北京航空航天大学学报, 2023, 49(5): 1044-1052.
- [12] 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.
- [13] DU W B, ZHANG M Y, ZHANG Y, et al. Delay causality network in air transport systems[J]. Transportation Research Part E: Logistics and Transportation Review, 2018, 118: 466-476.

## Optimization of Flight Delay Diffusion Prediction Based on CNN and SEIR Models

ZHU Daiwu, CAI Linjun, ZHANG Hanwen

(Air Traffic Management College, Civil Aviation Flight University of China, Guanghan 618307, Sichuan, China)

**Abstract:** The delay diffusion phenomenon caused by large-scale flight delays has a significant impact on air traffic networks. In order to better predict and control delay diffusion, a delay diffusion prediction model combining convolutional neural network (CNN) and traditional epidemiological SEIR(susceptible-exposed-infectious-recovered) model is proposed for the nonlinear and complex characteristics of flight delay diffusion, as well as for the difficulty of combining real-time and accuracy. Based on the flight delay diffusion propagation mechanism and SEIR model, a flight delay diffusion dynamics model was established, and the key parameters in the model are optimized by convolutional neural network. The optimized model was simulated using MATLAB, and the accuracy was improved by 17.95% compared with the traditional SEIR model after combining the CNN model.

**Keywords:** flight operation; flight delay diffusion; flight chain; SEIR(susceptible-exposed-infectious-recovered) model; convolutional neural network(CNN)