

# 基于级联BP神经网络的航班撤轮挡时刻预测

徐涛<sup>1,2,3</sup> 丁杨<sup>1,2</sup> 卢敏<sup>1,2,3</sup>

<sup>1</sup>(中国民航大学计算机科学与技术学院 天津 300300)

<sup>2</sup>(中国民航信息技术科研基地 天津 300300)

<sup>3</sup>(民航旅客服务智能化应用技术重点实验室 北京 101318)

**摘要** 合理的航班协同离场前排序可以提高机场、航空公司、空管等部门的运行效率和可预测性,减少航班起飞前的等待时间。准确地预测航班撤轮挡时刻是建立航班起飞顺序的先决条件,对调整起飞前航班排序和计算航班起飞时间具有重要的决策意义。提出一个基于级联BP神经网络的航班撤轮挡时刻预测模型。该模型分别在航班过站过程的不同时刻进行航班撤轮挡时刻的预测,并进行过拟合研究。实验结果表明,与目前采用的经验统计预测模型相比,在相同时刻,该预测模型具有更高的预测准确率。

**关键词** 航班撤轮挡时刻预测 BP神经网络 级联模型 里程碑事件 过拟合 协同决策

**中图分类号** TP339 **文献标识码** A **DOI**:10.3969/j.issn.1000-386x.2019.06.042

## FLIGHT OFF-BLOCK TIME PREDICTION BASED ON CASCADED BP NEURAL NETWORK

Xu Tao<sup>1,2,3</sup> Ding Yang<sup>1,2</sup> Lu Min<sup>1,2,3</sup>

<sup>1</sup>(College of Computer Science and Technology, Civil Aviation University of China, Tianjin 300300, China)

<sup>2</sup>(Information Technology Research Base of Civil Aviation Administration of China, Tianjin 300300, China)

<sup>3</sup>(Key Laboratory of Intelligent Passenger Service of Civil Aviation, CAAC, Beijing 101318, China)

**Abstract** A reasonable arrangement of pre-departure sequence of flights can improve the efficiency and predictability of airport, airline and blank pipe, and reduce the waiting time before the aircrafts take off. Accurate prediction of the flight off-block time is a prerequisite for the establishment of a pre-departure sequence, which has important decision significance for adjusting the flight departure order and calculating the flight departure time. This paper proposed a flight off-block time prediction model based on cascaded BP neural network. The model predicted the flight off-block time at different times of the flight turnaround process, and made over-fitting study. The experimental results show that compared with the empirical statistical prediction model currently used, the model has higher prediction accuracy at the same time.

**Keywords** Flight off-block time prediction BP neural network Cascaded model Milestone event Overfitting Collaborative decision making

## 0 引言

协同离场前航班排序是在考虑到各参与方(机场、航空公司、空管)偏好的前提下,安排飞机离开停机位准备起飞的顺序<sup>[1]</sup>。一个合理的航班起飞顺序可以提高各参与方的运行效率,减少航班起飞前的等待

时间。其中航空公司通过目标撤轮挡时刻 TOBT(Target Off-Block Time)来表达对航班起飞的先后秩序的偏好。TOBT是指飞机在起飞准备就绪、所有舱门关闭、廊桥撤离、推车可用并且收到开车许可后可立即推出的时间。及时、准确、稳定的 TOBT是建立航班起飞顺序的先决条件,对调整航班起飞排序和计算航班起飞时间具有重要的决策意义<sup>[2]</sup>。

现有的 TOBT 计算方法是针对大量历史运行数据通过经验统计得到各保障环节的平均时间或平均最小过站时长 MTTT (Minimum Turn-round Time)、预计着陆时刻 ELDT (Estimated Landing Time) 和预计滑入时刻 EXIT (Estimated Taxi-In Time), 然后求和作为 TOBT<sup>[3]</sup>。然而, 对于大型枢纽机场, 由于航班过站影响因素的复杂性, 不同航班的过站保障时间有较大差异, 因此, 很难对单一过站时长的持续时间进行预测, 严重影响 TOBT 的计算精度, 难以保证协同决策的正确实施。

本文通过研究航班过站保障过程, 利用枢纽机场提供的飞机过站大量地面保障真实数据, 采用 BP 神经网络, 进行过拟合研究, 构建级联模型, 在航班过站过程的不同时刻分别进行航班撤轮挡预测, 为航班评估 TOBT, 进行过站保障决策、建立合理的协同离场前航班排序提供参考。

## 1 相关知识

### 1.1 协同决策系统

为提高空中交通流量和机场利益相关方的运行效率, 2012 年, 民航正式启用协同决策 CDM (Collaborative Decision Making) 系统。CDM 是一种基于资源共享和信息交互的多主体(空管、机场、航空公司等)联合协作运行理念。CDM 系统将航班进港至离港的过站过程期间发生的重要事件定义为里程碑事件 (Milestone Event), 实现对航班过站保障情况的密切跟踪与监测。

一个完整的航班过站保障过程是指从飞机停靠停机位开始到推出飞机准备起飞之间的一系列为保障后续飞行任务正常所进行的地面保障服务<sup>[4]</sup>。里程碑事件是指对航班过站时, 从计划执行到本场起飞各个关键业务节点的定义<sup>[5]</sup>。通过一系列里程碑事件来跟踪、预测航班动态并与航班过站保障各参与方协同, 获得更加高效的协同运行, 目的是将相互关联的航班过站过程合成为一个无缝流程。

### 1.2 BP 神经网络

BP 神经网络可以实现从输入到输出的任意复杂的映射关系, 并具有良好的泛化能力, 在预测过程中对实验数据具有很好的复杂模式识别和函数拟合<sup>[6]</sup>。

算法基本步骤如下:

(1) 网络初始化。根据输入输出序列确定网络输入节点数  $n$  与输出节点数  $m$ , 并确定隐含层节点数  $l$ ; 然后初始化输入层、隐含层、输出层神经元之间的连接

权值以及隐含层与输出层的阈值; 最后给定学习速率、训练次数与神经元激励函数。

(2) 隐含层输出。根据输入变量、输入层和隐含层间连接权值以及隐含层阈值求得激励函数的变量, 代入激励函数中计算隐含层输出:

$$H_j = f\left(\sum_{i=1}^n w_{ij}x_i - a_j\right)$$

式中:  $x_i$  表示输入序列中的第  $i$  个参数,  $w_{ij}$  表示第  $i$  个输入层节点与第  $j$  个隐含层节点间的权值,  $a_j$  表示第  $j$  个隐含层节点的阈值,  $H_j$  表示第  $j$  个隐含层节点的输出,  $f$  为激活函数, 其中  $j=1, 2, \dots, l$ 。

(3) 输出层输出。根据隐含层输出, 隐含层与输出层连接权值和输出层的阈值, 计算网络输出层的输出:

$$O_k = \sum_{j=1}^l H_j w_{jk} - b_k$$

式中:  $w_{jk}$  表示第  $j$  个隐含层节点与第  $k$  个输出层节点间的权值,  $b_k$  表示第  $k$  个输出层节点的阈值,  $O_k$  表示第  $k$  个输出层节点的输出, 其中  $k=1, 2, \dots, m$ 。

(4) 误差计算。根据网络输出层的预测输出和输出序列, 计算网络预测误差:

$$e_k = y_k - O_k$$

式中:  $y_k$  表示输出序列中的第  $k$  个参数,  $e_k$  表示第  $k$  个输出参数与实际值的误差。

(5) 权值更新。预测误差反向传播, 根据网络预测误差更新网络连接权值:

$$w_{ij} = w_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m w_{jk} e_k$$

$$w_{jk} = w_{jk} + \eta H_j e_k$$

式中:  $\eta$  表示网络的学习速率。

(6) 阈值更新。根据网络预测误差更新网络节点阈值:

$$a_j = a_j + \eta H_j (1 - H_j) x_i \sum_{k=1}^m w_{jk} e_k$$

$$b_k = b_k + e_k$$

(7) 判断算法迭代是否结束, 若否, 返回步骤(2)。

## 2 模型构建

### 2.1 BP 神经网络模型

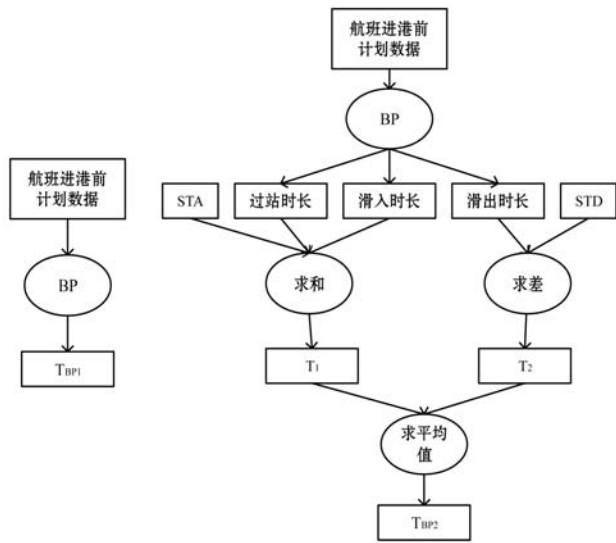
在航班进港前, 针对大量历史数据通过经验统计估计航班的 EXIT、MTTT 与预计滑出时长 EXOT (Estimated Taxi-Out Time), 结合已公布的计划时间 ELDT、计划进港时间 STA (Scheduled Time of Arrival)、计划离港时间 STD (Scheduled Time of Departure) 预测出航班

撤轮挡时刻,并以此更新 TOBT。目前,常用的经验统计预测模型有两种,分别记为  $TOBT^{CDM1}$  和  $TOBT^{CDM2}$ ,撤轮挡时刻计算公式为:

$$T_{CDM1} = ELDT + EXIT + MTTT \quad (1)$$

$$T_{CDM2} = \frac{(STA + EXIT + MTTT) + (STD - EXOT)}{2} \quad (2)$$

参照上述两种经验统计预测模型,以航班计划数据作为航班进港前航班撤轮挡时刻预测的输入数据,设计基于 BP 神经网络的航班进港前航班撤轮挡时刻预测模型,包括模型  $TOBT^{BP1}$ 、 $TOBT^{BP2}$  (如图 1 所示)。



(a)  $TOBT^{BP1}$  模型 (b)  $TOBT^{BP2}$  模型  
图 1 航班进港前 BP 神经网络预测模型

$TOBT^{BP1}$  模型:以 STA、STD、结束登机人数、MTTT 作为 BP 神经网络的输入直接预测航班撤轮挡时刻  $T_{BP1}$ 。

$TOBT^{BP2}$  模型:首先利用 BP 神经网络预测航班滑入时长、过站时长、滑出时长。通过 STA、航班滑入时长预测值与航班过站时长预测值求和得到  $T_1$ ,STD 减去航班滑出时长预测值到得到  $T_2$ ,以  $T_1$  与  $T_2$  的平均值作为航班撤轮挡时刻  $T_{BP2}$ 。

在航班入位时、航班值机结束时和客舱门关闭时,分别以当前已获得的航班过站保障数据和公布的 TOBT 作为单隐含层 BP 神经网络的输入,直接预测航班撤轮挡时刻。

## 2.2 级联 BP 神经网络航班撤轮挡时刻预测模型

级联模型由多个不同或相同的模型组成,不同层级模型可以强化处理不同的数据,且相对独立,上一级的输出可以作为后续层级的输入,各级模型协同工作<sup>[7-8]</sup>。通常级联模型有串联与并联两种结构<sup>[9]</sup>,如图 2-图 3 所示。




图 2 串联级联模型

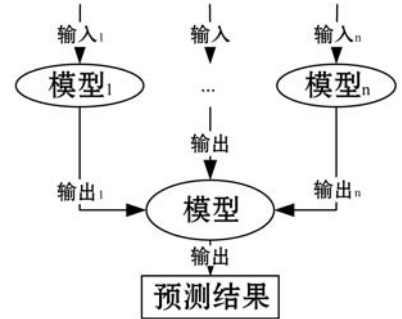


图 3 并联级联模型

若采用并联级联模型,则以过站过程中各个子过程的里程碑事件发生时刻作为各模型的输入,各个子过程的时长作为各模型的输出,再以子过程时长的预测值作为输入来预测航班撤轮挡时刻。由于时长的预测值与真实值之间存在误差,以此预测值作为输入进行预测,会导致误差的积累,从而使模型预测的准确性大大降低。因此,本文拟采用串联级联模型,以上一层的输入输出与当前新的航班过站保障数据作为当前层的输入进行当前里程碑事件发生时刻的航班撤轮挡时刻预测,即:

$$T_{current} = BP(T_{pre}, C_p) \quad (3)$$

式中: $T_{current}$  表示当前时刻的航班撤轮挡时刻预测结果; $T_{pre}$  表示前一时刻的航班撤轮挡时刻预测结果; $C_p$  表示当前的神经网络的输入。

实现的级联 BP 神经网络航班撤轮挡时刻预测模型如图 4 所示。

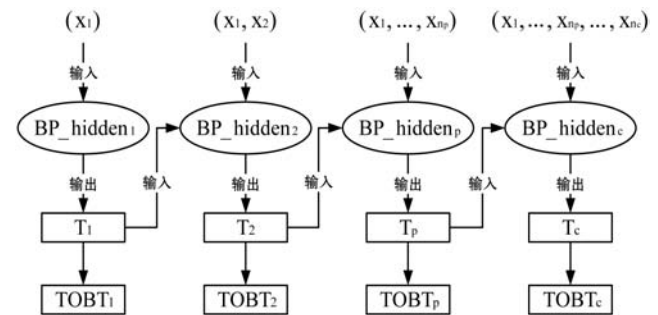


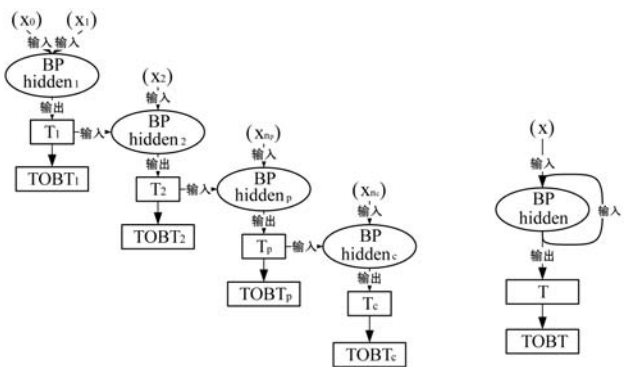
图 4 基于级联 BP 神经网络的航班撤轮挡时刻预测模型

根据问题的需要,设计  $c$  层级的级联模型,  $(x_1, x_2, \dots, x_p)$  表示级联模型中第  $p$  层级的输入序列,  $p = 1, 2, \dots, c$ ;  $T_p$  表示第  $p$  层级的输入序列的预测结果;  $TOBT_p$  表示第  $p$  层级评估的目标撤轮挡时刻。

直观上,本文的级联 BP 神经网络模型与递归神经网络模型(RNN)比较相似,但是,CDM 系统要求,在每一个里程碑事件的发生时刻需要重新预测航班撤轮

挡时刻并更新 TOBT,以保证协同离场前航班排序的合理性。若航班撤轮挡时刻预测值偏离 CDM 系统公布的 TOBT 过多,航空公司必须启动额外的飞行计划延迟。因此,每一次的航班撤轮挡时刻预测结果不仅需要保障已发生里程碑事件时间的合理性,而且对后续里程碑事件时间具有指导意义。

另外,航班进港到离港的整个过程有一个严格的先后保障顺序,即通常每个里程碑事件依赖于其前序里程碑事件<sup>[10]</sup>。因此,为了提高预测准确率,需要充分利用里程碑事件发生时刻之间的强顺序关联性。如图 5 所示。



(a) 结构递归神经网络 (b) 时间递归神经网络  
图 5 递归神经网络模型

结构递归神经网络的结构类似一棵二叉树(如图 5(a)所示),有 2 个输入和 1 个输出,其输出作为下一次预测的一个输入。由网络结构可知,结构递归神经网络无法充分利用里程碑事件发生时刻之间的强顺序关联性。

时间递归神经网络的核心是对前一次网络隐含层的存储(如图 5(b)所示),即要求每次预测的网络模型具有相同的隐含层。由于需要考虑里程碑事件之间的强关联性,因此每一次的输入的维度不同,而对于具有相同隐含层的时间递归神经网络无法保证对不同维度的输入有较高的预测精度。

本文提出的级联 BP 神经网络模型不仅在每一个里程碑事件的发生时刻需要重新预测航班撤轮挡时刻,而且能够充分利用里程碑事件发生时刻之间的强顺序关联性,因此本文采用级联 BP 神经网络模型。

### 3 实验结果与分析

#### 3.1 实验评价指标与参数设置

在机场实际运行中,准确地预测航班撤轮挡发生时刻非常困难,且没有太多实际意义,因此,发生时刻的预测只要在一个合理区间即可。同时,由协同决策

系统运行规程可知,如果航班撤轮挡时刻预测值偏离公布的 TOBT 超过 15 min,航空公司必须启动额外的飞行计划延迟消息<sup>[11]</sup>。因此,本文实验以不启动飞行计划延迟消息的基于区间间隔的预测准确率为目标,分别统计航班撤轮挡时刻预测值与实际航班撤轮挡时刻之间的误差在  $\pm r$  min 的航班占总航班数的百分比作为预测准确率, $r$  分别取值 5、10、15。于是, $g$  条测试数据的预测误差在  $\pm r$  的预测准确率计算公式如下:

$$Error(r) = \frac{1}{g} \sum_{i=1}^g \begin{cases} 1 & |y_i - o_i| \leq r \\ 0 & |y_i - o_i| > r \end{cases} \quad (4)$$

本文采用单隐含层 BP 神经网络,通过对实验数据的整理和对隐含层节点个数的选取,确定 BP 神经网络的规模如表 1 所示。

表 1 BP 神经网络规模

	输入层节点数	隐含层节点数
航班进港前	4	5
航班入位时	9	11
值机结束时	16	20
客舱门关闭	22	25

通过获取  $[-1, 1]$  之间的随机数的方式初始化输入层、隐含层、输出层神经元之间的连接权值以及隐含层与输出层的阈值。给定学习速率为 0.1,训练次数为 1 000,激励函数为 Sigmoid 函数。

考虑到空地协同需求及枢纽机场所提供的航班过站地面保障数据,本文选取航班进港前、航班入位时、航班值机结束时和航班客舱门关闭时 4 个关键里程碑事件的发生时刻进行航班撤轮挡时刻预测。

#### 3.2 实验数据划分

在实验过程中发现,直接通过 BP 神经网络进行预测可能会发生过拟合现象。过拟合是指为了得到一致假设而使假设变得过度严格,即网络模型把数据学习的过于彻底,以至于把噪声数据的特征也学习到了,导致在后期测试的时候不能够很好地识别数据<sup>[12]</sup>。

以航班入位时预测实验为例,分别设置不同的权值迭代次数,以训练好的 BP 神经网络模型对测试数据进行预测,训练误差与测试误差的变化如图 6 所示。纵坐标为预测值与实际值之间的平均误差,横坐标为 BP 神经网络的迭代次数。当模型的迭代次数不超过 10 次时,预测误差与测试误差都在减小,之后,训练误差继续减少并趋于稳定,而测试误差开始增大,由此可以判断,实验结果过拟合了。




图6 航班入位时预测误差走势图

为了解决过拟合问题,实验首先采用了 Dropout 的方法。Dropout 是指在深度学习网络的训练过程中,对神经网络单元按照一定的概率将其暂时从网络中丢弃,减弱了神经元节点间的联合适应性,增强了网络模型的泛化能力<sup>[13]</sup>,以单隐层节点为例,如图7所示。




图7 Dropout 效果图

设置隐含层节点失效概率为 0.5,以航班入位时预测实验为例,经 Dropout 处理后的 BP 神经网络的训练误差与测试误差的变化如图8所示。




图8 Dropout 后误差变化图

从图8可见,Dropout 方法减小了过拟合现象,但预测结果并不稳定。经研究发现,这是由于在大型枢纽机场中,不同类型航班的过站保障时间具有十分明显的差异,导致神经网络无法充分地进行学习,因此,采用数据划分的方法。

在安排航班飞行计划时,航空公司会针对不同类型的航班分别进行安排,其中,航班过站保障时间是航空公司划分航班的重要参考数据,而停机位、机型与航

站楼决定了航班过站保障时间。

为了考察停机位、航班机型、航站楼对航班过站保障时间的影响,本文统计了某大型枢纽机场 2015 年全年停靠不同机位(远机位和近机位)、不同机型(中机型和大机型)、不同航站楼(1号、2号航站楼)航班的平均过站时长,其统计结果如图9-图11所示。




图9 不同停机位的每天航班过站平均时长




图10 不同机型的每天航班过站平均时长




图11 不同航站楼的每天航班过站平均时长

从图9-图11可以看出,停靠远机位、2号航站楼的航班的滑入时长明显更长,而停靠远机位、1号航站楼、大机型的航班的过站时长明显更长。实验将按照“停机位-机型-航站楼”进行实验数据的划分,分别对不同类型的航班进行航班撤轮挡时刻预测实验。以“近机位-中机型-2号航站楼”数据为例,BP神经网络的训练误差与测试误差的变化如图12所示。




图 12 数据划分后误差变化图

从图 12 可见经过数据划分后,不仅消除了过拟合现象,而且预测误差有明显的减小。

综上,为了避免过拟合的发生,以下实验均以“近机位-中机型-2 号航站楼”数据为例,其中,样本数据为 6 961 条,测试数据 1 710 条。

### 3.3 基于 BP 神经网络的航班进港前预测实验

本节通过实验对比了经验统计预测模型与基于 BP 神经网络的航班进港前航班撤轮挡时刻预测模型。

表 2 给出了航班进港前基于经验统计模型与 BP 神经网络的航班撤轮挡时刻预测模型的预测误差在  $\pm 5 \text{ min}$ 、 $\pm 10 \text{ min}$  和  $\pm 15 \text{ min}$  的预测准确率。

表 2 航班进港前航班撤轮挡时刻预测结果 %

模型	预测准确率		
	Error(5)	Error(10)	Error(15)
TOBT <sup>CDM1</sup>	17.44	35.28	53.25
TOBT <sup>CDM2</sup>	46.75	73.38	82.68
TOBT <sup>BP1</sup>	34.00	66.71	81.92
TOBT <sup>BP2</sup>	53.07	77.12	84.90

由实验结果可以看出,TOBT<sup>BP2</sup> 与 TOBT<sup>BP1</sup> 模型预测准确率要远好于实验 TOBT<sup>CDM2</sup> 与 TOBT<sup>CDM1</sup>, 预测误差为  $\pm 5 \text{ min}$  的预测准确率分别提高了 16.56%、6.32%; 预测误差为  $\pm 10 \text{ min}$  的预测准确率分别提高了 31.43%、3.74%; 预测误差为  $\pm 15 \text{ min}$  的预测准确率分别提高了 28.67%、1.22%。因此,可以得出结论:对于航班进港前的航班撤轮挡时刻预测,通过 BP 神经网络的预测准确性远高于现有的经验统计预测模型。

此外,TOBT<sup>BP2</sup> 模型实验结果也远好于 TOBT<sup>BP1</sup>, 预测误差为  $\pm 5 \text{ min}$ 、 $\pm 10 \text{ min}$  与  $\pm 15 \text{ min}$  的预测准确率分别提高了 19.07%、10.41% 和 2.98%。因此,可以得出结论:通过预测航班滑入时长、过站时长和滑出时长,然后以求平均值的预测模型的预测准确率更高。

### 3.4 基于级联模型的航班预测实验

为体现实验的完整性,本节实验以 CDM 系统最终公布的 TOBT 估计值(标记为 TOBT<sup>CDM</sup>)和 3.3 节的航班进港前航班撤轮挡时刻预测实验中预测结果最好模型作为比较对象。

按照图 4 所示的级联模型,利用 3.3 节基于 BP 神经网络的航班进港前撤轮挡时刻预测模型 TOBT<sup>BP2</sup> 的预测值作为本实验的一个输入,分别构建航班入位时航班撤轮挡时刻预测模型(TOBT<sup>ABT</sup>)、航班值机结束时航班撤轮挡时刻预测模型(TOBT<sup>ASBT</sup>)和航班客舱门关闭时的航班撤轮挡时刻预测模型(TOBT<sup>ARDT</sup>),其实实验结果如表 3 所示。

表 3 航班过站撤轮挡时刻预测结果 %

模型	预测准确率		
	Error(5)	Error(10)	Error(15)
TOBT <sup>CDM</sup>	53.42	66.18	73.90
TOBT <sup>BP2</sup>	53.07	77.12	84.90
TOBT <sup>ABT</sup>	58.46	87.99	96.55
TOBT <sup>ASBT</sup>	61.97	89.17	97.13
TOBT <sup>ARDT</sup>	71.85	92.39	98.19

考虑到航班撤轮挡时刻的预测必须具有实时性和时效性,因此本文统计了不同时刻基于级联 BP 神经网络的航班撤轮挡时刻预测模型计算所需要的时间(如图 13 所示)。




图 13 不同时刻基于级联 BP 神经网络航班撤轮挡时刻预测时长

实验结果表明,在航班入位时、值机结束时和客舱门关闭时的撤轮挡时刻预测值的准确性要远好于航班进港前的预测值与 CDM 系统最终公布的 TOBT。另外,随着航班过站保障服务的推进,撤轮挡时刻预测值的准确性在不断提高。相较于航班进港前的预测准确率,在航班入位时,预测误差为  $\pm 5 \text{ min}$ 、 $\pm 10 \text{ min}$  与  $\pm 15 \text{ min}$  的预测准确率分别提高了 5.39%、10.87% 和 11.65%; 在航班值机结束时,预测误差为  $\pm 5 \text{ min}$ ,

$\pm 10$  min 与  $\pm 15$  min 的预测准确率分别提高了 8.9%、12.05% 和 12.23%；在航班客舱门关闭时,预测误差为  $\pm 5$  min,  $\pm 10$  min 与  $\pm 15$  min 的预测准确率分别提高了 18.78%、15.27% 和 13.29%。同时,由图 13 实验结果可见,在不同的时刻,基于级联 BP 神经网络的航班撤轮挡时刻预测模型的预测时间都保证在 0.1 s 以内,从而确保了预测结果的实时性和时效性。

## 4 结 语

航班撤轮挡时刻的准确预测不仅可以为航空公司评估航班 TOBT,安排航班起飞队列提供参考,也便于机场合理调配资源。为了更准确地预测撤轮挡时刻,本文通过构建级联 BP 神经网络模型,并进行过拟合分析,利用航班计划数据与航班过站保障数据,分别在航班进港前、航班入位时、航班值机结束时与航班客舱门关闭时进行航班撤轮挡时刻预测,并与现有的经验统计预测模型进行比较。通过实验验证,本文提出的基于级联 BP 神经网络的航班撤轮挡时刻预测模型的预测准确性要远好于现有的经验统计预测模型。另外,在航班进港前,预测准确率在允许容差  $\pm 15$  min 内的航班数占总航班数的 84.9%,航班入位时可以达到 95% 以上,并且,随着航班过站流程的推进,预测的准确性在不断提高。因此,本文提出的预测模型具有很好的实用性、时效性与可参考性,可以大大减少人工干预的次数,提高系统决策的效率。

## 参 考 文 献

- [ 1 ] Kunze T, Oreschko B, Fricke H. Aircraft Turnaround Management in a Highly Automated 4D Flight Operations Environment [ D ]. Dresden: Technische University Dresden, 2012.
  - [ 2 ] Groppe M. Influences on Aircraft Target Off-Block Time Prediction Accuracy [ D ]. Cranfield University, 2011.
  - [ 3 ] Gok Y S. Scheduling of Aircraft Turnaround Operations Using Mathematical Modelling: Turkish Low-cost Airline as a Case Study [ D ]. Institutional Repository for Coventry University, 2014.
  - [ 4 ] 冯霞, 张鑫, 陈锋. 飞机过站上客过程持续时间分布 [ J ]. 交通运输工程学报, 2017, 17(2): 98 - 105.
  - [ 5 ] Oreschko B, Schultz M, Elfle J, et al. Significant Turnaround Process Variations due to Airport Characteristics [ C ] // Proceedings of International Air Transport & Operations Symposium, 2010: 263 - 270.
  - [ 6 ] 陈刚, 周杰, 张雪君, 等. 基于 BP 与 RBF 级联神经网络的日负荷预测 [ J ]. 电网技术, 2009(12): 101 - 105.
  - [ 7 ] 张玄武, 郑耀, 杨波威, 等. 基于级联前向网络的翼型优化设计 [ J ]. 浙江大学学报(工学版), 2017, 51(7): 1405 - 1411.
  - [ 8 ] Sun X, Peng X, Ren F. Detect the Emotions of the Public based on Cascade Neural Network Model [ C ] // Proceedings of IEEE/ACIS, International Conference on Computer and Information Science. IEEE, 2016: 1 - 6.
  - [ 9 ] 张宇楠, 曾实. 三种模型级联的比较 [ J ]. 原子能科学技术, 2014, 48(11): 1921 - 1927.
  - [ 10 ] 徐涛, 赵晨旭, 卢敏. 基于因子分析的航班撤轮挡时刻预测方法 [ J ]. 计算机工程与设计, 2017(11): 3011 - 3017.
  - [ 11 ] Chatterji G, Zheng Y. Wheels-Off Time Prediction Using Surface Traffic Metrics [ C ] // Proceedings of AIAA Aviation Technology, Integration, and Operations. 2012: 4167 - 4180.
  - [ 12 ] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting [ J ]. The Journal of Machine Learning Research, 2014, 15(1): 1929 - 1958.
  - [ 13 ] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [ C ] // International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012: 1097 - 1105.
- 
- (上接第 225 页)
- [ 7 ] Cui A, Costello M, Stolfo S J. When Firmware Modifications Attack: A Case Study of Embedded Exploitation [ C ] // the 20th Annual Network & Distributed System Security Symposium, 2013.
  - [ 8 ] Bambenek. Hacking HP Printers for Fun and Profit [ EB/OL ]. [ 2011 - 11 - 29 ]. <https://isc.sans.edu/diary/Hacking+HP+Printers+for+Fun+and+Profit/12112>.
  - [ 9 ] 李成林. Rootkit 的改进型实现与检测技术研究 [ D ]. 南昌:江西师范大学, 2015.
  - [ 10 ] 冯培钧, 张平, 陈志锋, 等. 一种新型 Linux 内核级 Rootkit 设计与实现 [ J ]. 信息工程大学学报, 2016, 17(2): 231 - 237.
  - [ 11 ] 李扬, 周安民, 张磊, 等. 一种基于硬件虚拟化的 Rootkit 技术 [ J ]. 现代计算机: 中旬刊, 2017(2): 21 - 25.
  - [ 12 ] 孟晨宇, 阮阳, 王佳伟, 等. Rootkit 进程隐藏与检测技术研究 [ J ]. 软件导刊, 2016, 15(5): 188 - 190.
  - [ 13 ] 蒋和国, 蒋烈辉, 舒辉, 等. 基于 JTAG 仿真的 ARM Linux 设备 Bootkit 检测技术研究 [ J ]. 计算机应用研究, 2016, 33(2): 526 - 530.
  - [ 14 ] 刘文祺, 范明钰, 赵永福. 隐藏关系下计算机异常干扰检测方法仿真研究 [ J ]. 计算机仿真, 2018, 35(1): 424 - 427.