

DOI:10.16356/j.1005-2615.2015.04.007

基于贝叶斯网的航班过站时间动态估计

丁建立 赵键涛 曹卫东

(中国民航大学计算机科学与技术学院,天津,300300)

摘要:一架飞机每天要执行多个航班,从而形成航班链。前序航班进港后,若估计出飞机在机场的过站时间,后续航班的离港时间便可较准确给出。文中选取了对航班过站时间影响较为显著的几个因素,运用历史数据,采用最大似然估计进行贝叶斯网参数学习并获得不同情况下过站时间的估计值。同时,利用贝叶斯网增量学习的特性,运用航班增量数据基于贝叶斯估计修正贝叶斯网参数,并用新的学习结果更新过站时间估计值。实验数据表明,所提出的方法能较好地对飞机过站时间进行估计。最后,对影响过站时间的各因素进行了灵敏度分析对比。

关键词:航空运输;过站时间估计;贝叶斯网;增量学习;灵敏度分析

中图分类号:U8 **文献标志码:**A **文章编号:**1005-2615(2015)04-0517-08

Dynamic Estimation About Turnaround Time of Flight Based on Bayesian Network

Ding Jianli, Zhao Jiantao, Cao Weidong

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

Abstract: An aircraft needs to perform several flights one day, thus forming a flight chain. After the former flight arrives the estimate departure time of next flight could be obtained if the approximate turnaround time is acquired. This paper selects several notable factors which affect the turnaround time. Firstly, the Bayesian network is used to acquire estimate turnaround time by learning the parameters through maximum likelihood estimation based on historical data. Secondly, the incremental learning property of Bayesian network is used to revise the parameters of the model based on Bayesian estimation using the increased flight data and the turnaround time is updated by the new results. The experimental data indicate that the proposed method has good performance on estimating the turnaround time. Finally, the sensitivity analysis and comparison of the factors influencing turnaround time are carried out.

Key words: air transport; turnaround time estimation; Bayesian network; incremental learning; sensitivity analysis

航空运输具有快速、远距离运输能力的特点,是交通运输的一种重要方式。随着经济的发展,航空运输也得到快速发展。然而伴随航空运输业的

发展,航班延误问题越来越突出。由于航班延误,旅客拒绝登机,非法占据飞机等恶性事件屡见不鲜,有的航班延误事件甚至到了骇人听闻的地步。

基金项目:国家自然科学基金(60879015)资助项目;中国民航科技重大专项(MHRD201241)资助项目;中央高校基本科研业务费(3122014P004)资助项目。

收稿日期:2015-06-15;**修订日期:**2015-07-15

作者简介:丁建立,男,教授,主要研究方向:智能算法及航班延误、航空运输大数据及航空物流物联网。

通信作者:丁建立,E-mail:jlding@cauc.edu.cn。

针对航班延误,众多学者从不同角度进行了研究。在国外,Yufeng等人针对离港延误时间,研究了多种影响因素,用统计学方法得出延误时间的概率分布,对航班的离港延误时间进行预测^[1]。Eun等人提出了一种在终端区的航班到港排序优化方法,将提出的优化方法用于空中交通控制决策中,目的是减少航班进港延误的时间^[2]。Laskey等人运用贝叶斯网来描述航班延误结果与航班延误因素之间的关系,建立了一个随机模型。然后针对两个机场研究了影响航班离港延误的因素以及离港延误又是如何影响目的机场的进港延误^[3]。Pyrgiotis等人用排队论的思想建立了一个机场网络模型对航班延误进行研究,指出了在机场网络模型中考虑延误传播的重要性^[4]。在国内,针对航班延误,马正平等研究了机场发生延误的状况下,如何合理化恢复,以减小潜在损失^[5]。丁建立,徐涛等人采用生物免疫,支持向量机等方法对机场航班延误数量进行预测^[6-9]。曹卫东等人运用贝叶斯网对引起航班延误的各种因素和延误传播情况进行了研究^[10-11]。

应对航班延误,一种方法是在航班延误发生前,根据天气和机场状况等信息,及早向机场,航空公司发出预警,为各单位应对航班延误提供决策支持。另一种是在航班延误发生后,进行优化调度,尽可能地减少航班延误带来的损失。第二种方式已有部分研究成果,而第一种方式还有待进一步深入研究,这是因为影响航班延误的因素较多,随机性较大,航班延误的预测较为困难。同其他事物一样,在某些情况下航班运行也具有一定的规律,在大量的历史航班数据中包含了这些不易被发现的规律。因此,可以运用数据挖掘的方法对航班历史数据进行挖掘,从中发现这些潜在的规律,并运用挖掘出的信息对航班的延误状况进行预测。

1 航班过站时间及影响因素分析

1.1 航班过站时间

通常情况下,航空公司为了提高飞机的使用效率,会安排一架飞机在一天之内执行多个航班。图1为某飞机连续两天的航班执行情况。




图1 某飞机连续两天的航班执行情况

Fig. 1 Performance of aircraft in two days

留的时间即是过站时间。过站时间分为计划过站时间与实际过站时间。计划过站时间等于班期时刻表中规定的下一航班的起飞时间减去上一航班的降落时间,实际过站时间等于下一航班的实际起飞时间减去上一航班的实际降落时间。图2为计划过站时间与实际过站时间的关系。




图2 计划过站时间与实际过站时间关系

Fig. 2 Relationship between plan turnaround time and actual turnaround time

一般来说,实际过站时间同计划过站时间呈正相关关系,计划过站时间越长,实际过站时间也越长。但是受诸多因素的影响,使得图1中大部分点偏离了直线 $y=x$ (x 为计划过站时间, y 为实际过站时间),即实际过站时间并不严格等于计划过站时间。飞机进港后,倘若对过站时间有准确的估计,后续航班离港时间及延误情况也便可以得出,如图3所示。




图3 航班离港时间估计

Fig. 3 Estimation about departure time

因此,可以针对过站时间进行研究,对不同情况下的过站时间进行估计,从而达到对离港时间进行估计的目的。

1.2 过站时间影响因素分析

通过对历史数据分析,结合经验知识,确定对过站时间有影响的因素如下。

(1) 计划过站时间

在航班执行正常的情况下,飞机的实际过站时间和计划过站时间相差不大,在其他因素施加的影响下,实际过站时间才与计划过站时间有了偏差。发生延误时,当实际过站时间小于计划过站时间,能够吸收延误,当实际过站时间大于计划过站时间时,延误状况会加剧。

(2)前航班到达延误时间

前航班到达时间与航班时刻表中的到达时间相差不大时,下一航班发生起飞延误的可能性较小,实际过站时间与计划过站时间基本相等。当前航班到达时间晚于计划达到时间时,为了吸收延误,确保下一航班能够正常起飞,实际过站时间可能会小于计划过站时间。

(3)飞机类型

一般来说,机型越大,过站时间也越长。在下文的实验中,针对不同座位数,把飞机分成了4种类型,90座以下为机型A,90~160座为机型B,160~230座为机型C,230座以上为机型D。

(4)机场

不同的机场,过站时间会有所不同。在繁忙机场,飞机的过站时间相对于其他机场偏长。本文针对目前过内八大繁忙机场(北京首都机场、上海虹桥机场、上海浦东机场、广州白云机场、深圳宝安机场、成都双流机场、西安咸阳机场及昆明长水机场)和其他部分国内机场,对过站时间做了分析。除八大繁忙机场外,其他机场作为同一类机场。

(5)前航班到达时间段

当上述因素相同的条件下,在不同的时间段,实际过站时间可能会有不同。若前航班到达的时间是在机场相对繁忙的时间段,实际过站时间可能相对于其他时间段偏长。

2 贝叶斯网及过站时间动态估计

2.1 贝叶斯网概述

贝叶斯网起源于人工智能中的不确定性问题的研究,是概率论和图论相结合的产物。它一方面用图论的语言直观揭示问题的结构,另一方面又按照概率论的原则对问题的结构加以利用,降低推理的计算复杂度。贝叶斯网是一个有向无环图,其中节点代表随机变量,节点之间的边代表变量间的直接依赖关系。每个节点都附有一个概率分布,根节点所附的是它的边缘分布 $P(X)$,非根节点附的是条件概率分布 $P(X/\pi(X))$,其中 $\pi(X)$ 表示的是 X 的父节点。贝叶斯网将复杂的联合概率推理变成一系列相对简单的模块,从而大大降低了知识获取的难度和概率推理的复杂度,使人们可以把概率论应用于大型问题^[12]。

对于一般贝叶斯网,联合概率分布可以分解为

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i/\pi(X_i)) \quad (1)$$

贝叶斯网学习是指从数据中学习,得到贝叶斯网结构和参数的过程。在结构确定的条件下,贝叶斯网参数学习有两种方法:最大似然估计和贝叶斯估计。最大似然估计用于在先验知识未知的情况下,而贝叶斯估计用于有先验知识的情况下。

2.1.1 最大似然估计

一个由 n 个变量 $X=[X_1, X_2, \dots, X_n]$ 构成的贝叶斯网 N ,设节点 X_i 共有 r_i 个取值:1,2,..., r_i ,父节点 $\pi(X_i)$ 的取值共有 q_i 个组合:1,2,..., q_i ,网络参数为

$$\theta_{ijk} = P(X_i = k/\pi(X_i) = j) \quad (2)$$

式中: i 的取值范围为 $1 \sim n$,对于各异固定的 i, j 和 k 的取值范围分别为 $1 \sim q_i$ 和 $1 \sim r_i$ 。用 θ 表示所有 θ_{ijk} 组成的向量。设 $D=(D_1, D_2, \dots, D_m)$ 是一组关于 N 的完整数据,则 θ 的似然函数为

$$P(D/\theta) = \prod_{l=1}^m P(D_l/\theta) \quad (3)$$

对数似然函数为

$$l(\theta/D) = \log \prod_{l=1}^m P(D_l/\theta) = \sum_{l=1}^m \log P(D_l/\theta) \quad (4)$$

定义样本 D_l 的特征函数

$$\chi(i, j, k; D_l) = \begin{cases} 1 & \text{若 } X_i = k \text{ 且 } \pi(X_i) = j \\ 0 & \text{其他} \end{cases} \quad (5)$$

那么

$$\log P(D_l/\theta) = \sum_{i=1}^n \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} \chi(i, j, k; D_l) \log \theta_{ijk} \quad (6)$$

定义

$$m_{ijk} = \sum_{k=1}^m \chi(i, j, k; D_l) \quad (7)$$

则 m_{ijk} 是数据中满足 $X_i = k, \pi(X_i) = j$ 的样本数量。对数似然函数化为

$$\begin{aligned} l(\theta/D) &= \sum_{l=1}^m \sum_{i=1}^n \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} \chi(i, j, k; D_l) \log \theta_{ijk} = \\ &= \sum_{i=1}^n \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} \sum_{l=1}^m \chi(i, j, k; D_l) \log \theta_{ijk} = \\ &= \sum_{i=1}^n \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} m_{ijk} \log \theta_{ijk} \end{aligned} \quad (8)$$

式中 $\{m_{ijk}/i=1, \dots, n; j=1, \dots, q_i; k=1, \dots, r_i\}$ 为充分统计量。

对于固定的 i, j ,由于 $\sum_{k=1}^{r_i} \theta_{ijk} = 1$,当 θ_{ijk} 取如

下值时

$$\theta_{ijk}^* = \begin{cases} \frac{m_{ijk}}{\sum_{k=1}^{r_i} (m_{ijk})} & \sum_{k=1}^{r_i} (m_{ijk}) > 0 \\ \frac{1}{r_i} & \text{其他} \end{cases} \quad (9)$$

当表达式 $\sum_{k=1}^{r_i} m_{ijk} \log \theta_{ijk}$ 的值达到最大, 从而 $l(\theta/D)$ 达到最大。直观上有

$$\theta_{ijk}^* = \frac{D \text{中满足 } \pi(X_i) = j \text{ 并且 } X_i = k \text{ 的样本的数量}}{D \text{中满足 } \pi(X_i) = j \text{ 的样本的数量}} \quad (10)$$

2.1.2 贝叶斯估计

假设 $P(\theta_{ij} \cdot)$ 为狄利克雷分布 $D[\alpha_{ij1}, \alpha_{ij2}, \dots, \alpha_{ijr_i}]$, 在贝叶斯网全局独立性和局部独立性假设下

$$P(\theta) = \prod_{i=1}^n P(\theta_{i \cdot}) = \prod_{i=1}^n \prod_{j=1}^{q_i} P(\theta_{ij} \cdot) \propto \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} \theta_{ijk}^{\alpha_{ijk}-1} \quad (11)$$

为乘积狄利克雷分布。由贝叶斯公式

$$P(\theta/D) = \frac{P(\theta)P(D/\theta)}{\int P(D\theta)d\theta} = \frac{P(\theta)P(D/\theta)}{\int P(\theta)P(D/\theta)d\theta} = \frac{P(\theta)P(D/\theta)}{P(D)} \quad (12)$$

由于 $P(D)$ 为一归一化常数, 所以

$$P(\theta/D) \propto P(\theta)P(D/\theta) \quad (13)$$

即

$$P(\theta/D) \propto P(\theta) \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} \theta_{ijk}^{m_{ijk}} \quad (14)$$

$$P(\theta/D) \propto \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} \theta_{ijk}^{m_{ijk} + \alpha_{ijk} - 1} \quad (15)$$

$P(\theta/D)$ 也为乘积狄利克雷分布, 具有全局独立性和局部独立性, 并且 $P(\theta_{ij} \cdot / D)$ 为狄利克雷分布 $D[m_{ij1} + \alpha_{ij1}, m_{ij2} + \alpha_{ij2}, \dots, m_{ijr_i} + \alpha_{ijr_i}]$ 。 θ_{ijk} 的期望值为

$$\theta_{ijk}' = \int \theta_{ijk} P(\theta/D) d\theta = \int \theta_{ijk} P(\theta_{ij} \cdot / D) d\theta_{ij} \cdot = \int \theta_{ijk} P(\theta_{ijk} / D) d\theta_{ijk} \quad (16)$$

因为 $P(\theta_{ij} \cdot / D)$ 为狄利克雷分布 $D[m_{ij1} + \alpha_{ij1}, m_{ij2} + \alpha_{ij2}, \dots, m_{ijr_i} + \alpha_{ijr_i}]$, 所以

$$\theta_{ijk}' = \frac{m_{ijk} + \alpha_{ijk}}{\sum_{k=1}^{r_i} (m_{ijk} + \alpha_{ijk})} \quad (17)$$

2.2 过站时间动态估计

图4为过站时间估计的贝叶斯网结构图。当

各影响因素确定时, 各影响因素之间有没有因果关系, 过站时间的概率分布都是相同的。因而可以将用于过站时间估计的贝叶斯网模型结构简化为图4形式。

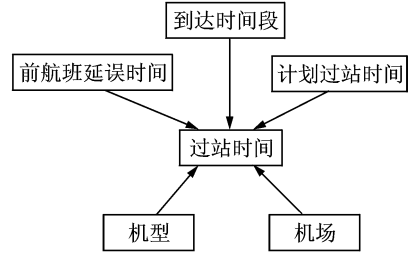


图4 过站时间估计贝叶斯网结构图

Fig. 4 Bayesian network structure about turnaround time

由于航班记录的不断增加, 需要对不断增加的航班数据进行学习。根据上面介绍的两种贝叶斯网参数学习方法, 可以把两种方法结合, 达到参数增量学习的目的。首先在没有先验知识的情况下采用最大似然估计进行贝叶斯网参数学习。在有新样本时, 把之前的学习结果作为先验知识, 采用贝叶斯估计修正贝叶斯网参数。这样能够顺序地加入训练数据, 使得模型参数能够动态调整。贝叶斯网参数动态修正流程如图5所示。

基于贝叶斯网参数动态修正的方法, 可以对过站时间进行动态估计, 图6为过站时间动态估计流程。

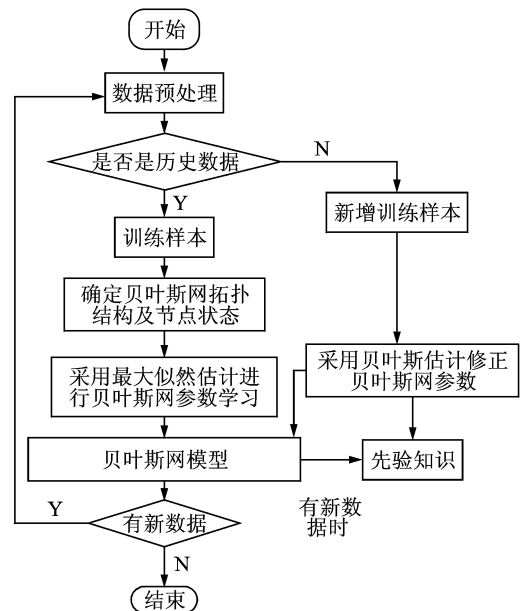


图5 贝叶斯网参数动态修正流程

Fig. 5 Revision process of Bayesian network parameter

首先对历史数据进行预处理得到训练样本,根据经验确定贝叶斯网结构,然后采用最大似然估计学习贝叶斯网参数。假设 θ_{ijk} 为贝叶斯网参数,根据式(9) 计算 θ_{ijk} ,其中 m_{ijk} 为历史数据中满足 $X_i = k$ 和 $\pi(X_i) = j$ 的样本的数量;若历史数据源

中 $\sum_{k=1}^{r_i} m_{ijk} = 0$,则设参数为均匀分布。计算完参数后,可对贝叶斯网模型进行推理,得出不同条件下的过站时间。当有新的训练样本时,把之前的学习结果作为先验知识,结合新的训练样本,根据式(17),采用贝叶斯估计修正贝叶斯网参数,其中 α_{ijk} 为先验知识中满足 $X_i = k$ 和 $\pi(X_i) = j$ 的样本的数量, m_{ijk} 为新样本中满足 $X_i = k$ 和 $\pi(X_i) = j$ 的样本的数量。这样当不断有新的数据产生时,重复以上过程,能够使贝叶斯网模型不断调整,以适应不断变化的情况。

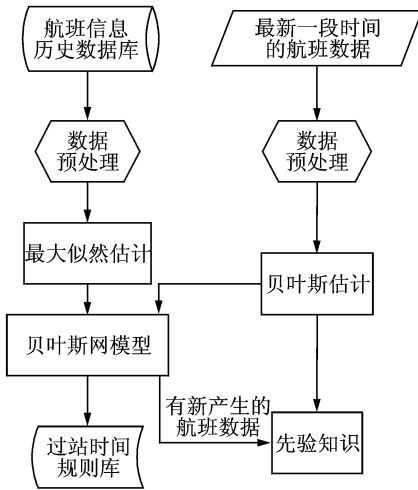


图 6 过站时间动态估计流程

Fig.6 Dynamic estimation process for turnaround time

2.3 实验结果及灵敏度分析

实验中所用的数据为国内某大型航空公司在某省的航班数据,从中选取对过站时间有影响的属性,用 5 个月的数据进行参数学习,得到的结果如图 7 所示。

经过之前的学习,把学习结果作为先验知识,再继续用 1 个月的数据对模型进行学习,学习后得到的结果如图 8 所示。通过比较可以看到各个变量的概率分布发生了细微的变化。当航班记录不断增加时,通过重复之前的过程,可以不断调整模

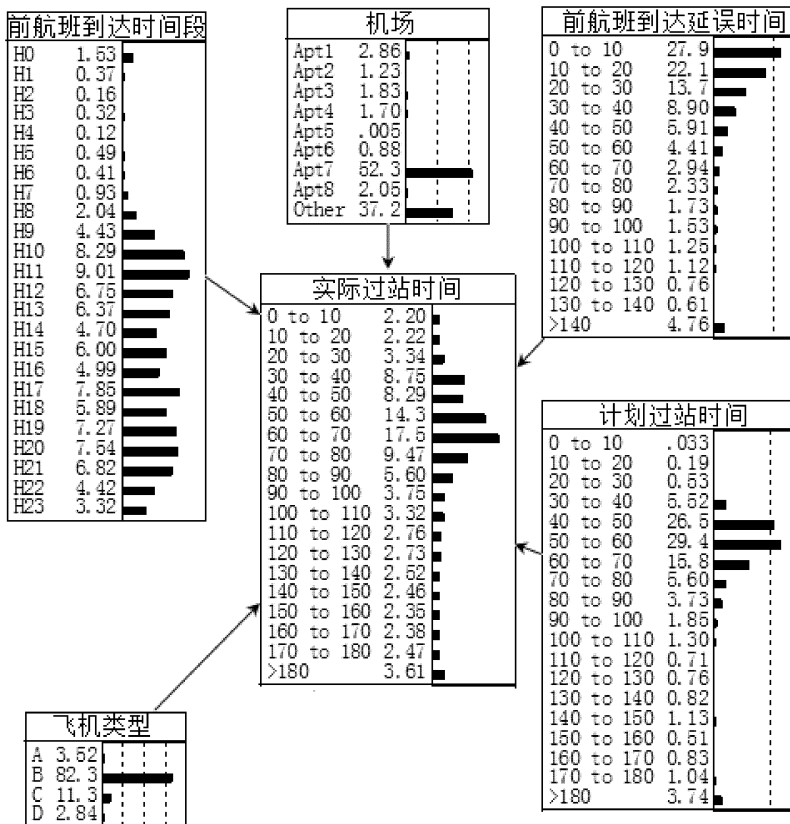


图 7 5 个月数据学习结果

Fig.7 Learning outcome using data in five months

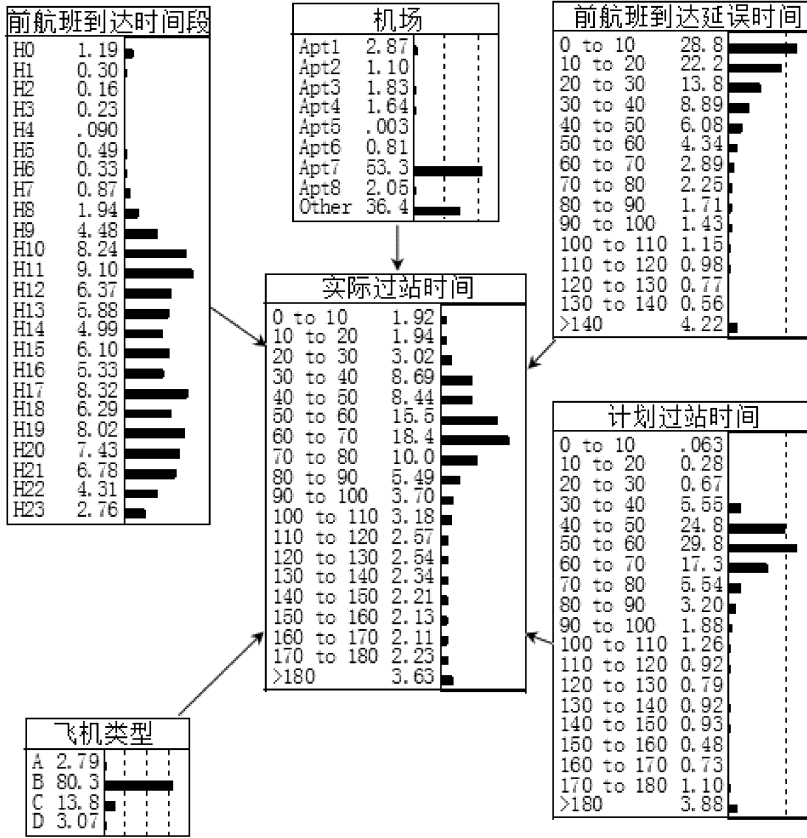


图8 增量学习结果

Fig. 8 Incremental learning outcome

型参数,以适应不断变化的情况。

若要得到一个确切的过站时间值,可以用期望值作为过站时间估计值。计算方法如下

$$E(t) = \sum_i P(i) * T_i \quad (18)$$

式中: $E(t)$ 为在其他条件确定时过站时间期望值; T_i 为第*i*个过站时间区间的中值; $P(i)$ 为过站时间在第*i*个区间中的概率。表1所示为部分情况下两种学习结果的过站时间估计值。

表1 过站时间估计值

Tab. 1 Estimated value of turnaround time

计划过站时间/min	前航班到达延误时间/min	飞机类型	机场	到达时间段	5个月数据学习结果过站时间估计/min	增量学习结果过站时间估计/min
90~100	60~70	B	Apt7	H10	72	71
60~70	0~10	C	Apt7	H8	65	68
60~70	0~10	D	Apt1	H10	75	72
50~60	30~40	B	Apt4	H14	95	91
100~110	90~100	B	Apt7	H17	70	73
40~50	20~30	B	Apt3	H18	78	79
50~60	30~40	B	Apt8	H21	72	73

当计划过站时间为90~100 min,前航班到达延误时间为60~70 min,飞机类型为B,到达机场为Apt7,到达时间段为上午10时时,两个学习结果的过站时间估计值分别为72 min和71 min。在

此种情况下,飞机到达已晚点严重,为了能够让后续航班恢复正常,吸收延误,实际过站时间小于计划过站时间。例如再对倒数第二条数据作分析,即使该飞机已经发生的前航班延误,但是在机场的繁

忙时间段,为了保证其他正常航班的执行,实际过站时间会大于计划过站时间,在此种情况下,延误会加剧。

再运用未来一个月的航班数据对以上两个学习结果的性能进行测试,以平均绝对误差作为评价模型性能的标准

$$MAE = \frac{\sum_{i=1}^n |y_i - y_i^*|}{n} \quad (19)$$

式中: y_i 为预测值, y_i^* 为真实值。表2给出了两个学习结果的误差。

表2 两种学习结果的预测误差

Tab. 2 Predicted error of two learning outcomes

学习结果	误差/min
5个月学习结果	7.2
增量学习结果	6.3

可以看到运用增量学习结果预测误差比5个月学习结果预测误差小,这是因为增量学习结果中对近期数据进行了学习,更能够反应最新的航班运行规律。但是并不是不断对新增加的数据进行学习就能持续减小误差,在运用此方法对过站时间估计时,误差范围存在一个下界。

在影响航班实际过站时间的因素中,有的影响比较显著,有的影响相对较小,为了分辨不同因素对实际过站时间影响的大小,对于上面的实验结果进行灵敏度分析^[13]。其中度量准则选取的是两个变量之间的互信息,其定义如下

$$I(Q, F) = H(Q) - H(Q | F) = \sum_{q, f} P(q, f) \log(P(q, f) / P(q)P(f)) \quad (20)$$

式中: Q 为查询变量,在本文中为实际过站时间; F 为其他变量; q 和 f 分别为查询变量和其他变量的某一状态。互信息可以用来衡量随机变量之间的相关性。单独观察 Q 时,得到的信息量是 $H(Q)$ 。在已知 F 后, Q 的信息量变为 $H(Q|F)$ 。了解了 F 后, Q 的信息量减少了 $I(Q, F) = H(Q) - H(Q|F)$ 。这个减少量是得知 F 后提供的关于 Q 的信息量。当 F 和 Q 相互独立时, F 的取值不会给 Q 提供任何信息量,因此 $I(Q, F) = 0$ 。当 F 和 Q 相互不独立时, $I(Q, F) > 0$ 。

分析结果如表3所示,其中变量与实际过站时间的互信息所占比重越大,表明影响越显著。

表3 各因素对实际过站时间影响大小的灵敏度分析

Tab. 3 Sensitivity analysis on factors influencing turnaround time

变量	互信息/bit	比重
实际过站时间	4.312 09	100
计划过站时间	0.176 50	4.09
飞机类型	0.064 27	1.49
机场	0.045 90	1.06
前航班到达时间段	0.041 66	0.966
前航班到达延误时间	0.023 22	0.538

从结果中可以看到,对实际过站时间的影响由大到小依次为计划过站时间、飞机类型、机场、前航班到达时间段及前航班到达延误时间。

3 结束语

本文针对航班链中飞机在机场的过站时间,分析了影响过站时间的不同因素,用贝叶斯网估计了不同状况下的过站时间。利用贝叶斯网增量学习的性质,可以动态修正模型参数,更新过站时间估计值。数据表明,采用的方法能够较好地对各种情况下的过站时间进行估计。最后对各影响因素进行了灵敏度分析。

参考文献:

- [1] Tu Yufeng, Ball M O, Jank W S. Estimating flight departure delay distributions—A statistical approach with long-term trend and short-term pattern[J]. Journal of the American Statistical Association, 2008, 103(481): 112-125.
- [2] Eun Y, Hwang I, Bang H. Optimal arrival flight sequencing and scheduling using discrete airborne delays[J]. Intelligent Transportation Systems, IEEE Transactions on, 2010, 11(2): 359-373.
- [3] Laskey K B, Xu N, Chen C H. Propagation of delays in the national airspace system[C]//Proceedings of the 22nd Conference on Uncertainty in Artificial Intelligence (UAI2006). [S. l.]: Computer Science—Artificial Intelligence, 2012.
- [4] Pyrgiotis N, Malone K M, Odoni A. Modelling delay propagation within an airport network[J]. Transportation Research Part C: Emerging Technologies, 2013, 27: 60-75.
- [5] 马正平, 崔德光. 机场航班延误优化模型[J]. 清华大学学报:自然科学版, 2004, 44(4): 474-477. Ma Zhengping, Cui Deguang. Optimizing airport flight delays[J]. Journal of Tsinghua University: Sci-

- ence and Technology. 2004,44(4):474-477.
- [6] 丁建立, 杨海彤, 顾彬. 基于模糊免疫策略的机场航班延误自适应实时预测方法[J]. 南京航空航天大学学报, 2011,43(2):257-261.
- Ding Jianli, Yang Haitong, Gu Bin. Adaptive real-time forecasting method of airdrome flight delay based on fuzzy immunization strategy[J]. Journal of Nanjing University of Aeronautics & Astronautics. 2011,43(2):257-261.
- [7] 丁建立, 仝冠生, 徐涛. 基于免疫否定选择算法的机场航班延误状态检测与实现[J]. 高技术通讯, 2008, 18(4):387-391.
- Ding Jianli, Tong Guansheng, Xu Tao. Detecting and implementing of airport scheduled flight delay state based on immune negative selection algorithm [J]. Chinese High Technology Letters. 2008,18(4): 387-391.
- [8] 徐涛, 丁建立, 顾彬, 等. 基于增量式排列支持向量机的机场航班延误预警[J]. 航空学报, 2009,30(7): 1256-1263.
- Xu Tao, Ding Jianli, Gu Bin, et al. Forecast warning level of flight delays based on incremental ranking support vector machine[J]. Acta Aeronautica et Astronautica Sinica, 2009,30(7):1256-1263.
- [9] 吕晓杰, 王红. 大型枢纽机场大面积航班延误预警方法研究[J]. 计算机工程与设计, 2009, 30(19): 4564-4566.
- Lv Xiaojie, Wang Hong. Method for swept flight delay early warning of large aeronautic hub[J]. Computer Engineering and Design, 2009, 30(19): 4564-4566.
- [10] 曹卫东, 贺国光. 连续航班延误与波及的贝叶斯网络分析[J]. 计算机应用, 2009,29(2):606-610.
- Cao Weidong, He Guoguang. Bayesian networks analysis for sequence flight delay and propagation[J]. Journal of Computer Applications. 2009, 29(2): 606-610.
- [11] 刘玉洁. 基于贝叶斯网络的航班延误与波及预测[D]. 天津:天津大学, 2009.
- Liu Yujie. Flight delay transmit forecast based on Bayesian Network [D]. Tianjin: Tianjin University, 2009.
- [12] 张连文, 郭海鹏. 贝叶斯网引论[M]. 北京:科学出版社, 2006.
- Zhang Lianwen, Guo Haipeng. Introduction to Bayesian network[M]. Beijing: Science Press, 2006.
- [13] Castillo E, Gutiérrez J M, Hadi A S. Sensitivity analysis in discrete Bayesian networks[J]. Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on, 1997,27(4):412-423.