

中文引用格式:李善梅,王端阳,唐锐,等. 基于时空关联规则与 LSTM 的机场进港延误等级预测[J]. 中国安全科学学报, 2025, 35(4):59-66.

英文引用格式:LI Shanmei, WANG Duanyang, TANG Rui, et al. Prediction of airport arrival delay level based on spatiotemporal association rules and LSTM [J]. China Safety Science Journal, 2025, 35(4):59-66.

基于时空关联规则与 LSTM 的机场进港 延误等级预测*

李善梅¹副教授, 王端阳¹, 唐锐², 李艳伟³教授, 李锦辉¹, 纪亚宏¹

(1 中国民航大学 空中交通管理学院, 天津 300300; 2 中国民用航空局 运行监控中心, 北京 100710; 3 中国民航大学 经济与管理学院, 天津 300300)

中图分类号: X949; V355.1

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2025.04.0476

基金项目: 天津市自然科学基金资助(24JCYBJC01170); 民航安全能力建设资金资助(ZH2025004, SKZ49420220027); 中国民航大学研究生科研创新项目(2024YJSKC03001)。

【摘要】 为提升空中交通运行安全, 提出一种基于时空关联规则挖掘和深度学习相结合的延误等级预测方法。首先, 选取平均航班延误时间和延误率作为机场进港延误度量指标, 并分析其时空关联特性; 其次, 基于模糊 C 均值(FCM)聚类算法划分机场进港延误等级, 并在此基础上, 基于频繁模式增长(FP-Growth)算法挖掘机场进港延误的时空关联规则; 然后, 基于规则数据以及延误指标数据构建样本数据, 作为长短时记忆(LSTM)模型的输入, 输出为未来时段机场进港延误等级, 同时引入注意力机制, 学习不同规则对预测结果的影响程度; 最后, 采用美国航班数据进行算例分析。结果表明: 总体预测的平均准确率达到 0.91, 不同时段的预测准确率均在 80% 以上, 注意力层网络的连接权重可解释预测结果。

【关键词】 时空关联规则; 长短时记忆(LSTM); 机场进港; 延误等级; 延误预测; 空中交通管理

Prediction of airport arrival delay level based on spatiotemporal association rules and LSTM

LI Shanmei¹, WANG Duanyang¹, TANG Rui², LI Yanwei¹, LI Jinhui¹, JI Yahong¹

(1 College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China;

2 Operation Supervisory Centre, Civil Aviation Administration of China, Beijing 100710, China;

3 College of Economics and Management, Civil Aviation University of China, Tianjin 300300, China)

Abstract: To improve the safety of air traffic operations, a delay level prediction method based on the combination of spatiotemporal association rule mining and deep learning was proposed. Firstly, the average flight delay time and delay rate were selected as airport delay metrics, and their spatial-temporal correlation characteristics were analyzed. Secondly, the airport delay levels were identified based on Fuzzy-C Means (FCM) clustering algorithm, and the spatiotemporal association rules of airport delay were mined based on (FP (Frequent Pattern) Growth) algorithm. Thirdly, sample data was constructed based on association rules and delay time series, which was put into LSTM model to predict the future airport

delay levels. At the same time, attention mechanism was introduced into the prediction model to learn the influence of different rules on prediction. Finally, the actual US flight data were collected for example analysis. The results show that the average prediction accuracy of overall delay levels reaches 0.91 and the prediction accuracy of different periods is all larger than 80%. The connection weight of the attention layer network reflects the influence of each rule on the prediction, which can be used to explain the prediction results.

Keywords: spatiotemporal association rules; long short term memory (LSTM); airport arrival; delay level; delay prediction; air traffic management

0 引言

随着我国航空运输业的快速发展,空中交通需求持续上升。中国大陆的商业航班在短短 10 年内实现了 1.76 倍的增长,从 2008 年的 422 万架次增长到 2019 年的 1 166 万架次^[1]。快速增长的空中交通需求与有限空域资源之间的矛盾日益突出,导致航班延误频发。2019 年,我国航班平均延迟时间约为 14 min,平均航班正常率约为 81.43%。航班延误会增大空中交通运行的无序性,增大空中交通管理人员的工作难度,严重威胁空中交通运行的安全性^[2]。航班延误早已成为评估空中交通管理的重要指标。为缓解延误的负面影响,开发有效的航班延误预测方法,已成为智能空中交通管理的关键。

近年来,由于大量空中交通数据可以获取,数据驱动的延误预测得到广泛关注。随机森林、贝叶斯网络等机器学习技术被用于航班延误预测,取得较好的预测效果,但该类浅层结构的学习模型对于高维交通数据和复杂延误模式的特征提取能力略显不足。深度学习模型在处理非线性和不确定性问题方面具有明显优势。KIM 等^[3]提出一种用于预测航班延误的长短时记忆(Long Short-Term Memory, LSTM)架构。LSTM 作为循环神经网络(Recurrent Neural Network, RNN)的变体,能够很好地提取输入交通状态参数间的依赖关系,并避免传统 RNN 在训练过程中所产生的梯度爆炸问题,但其仍然不能很好地学习到网络中各节点的空间依赖关系。为捕获航班延误在机场网络上的空间传播特性,QU Jingyi 等^[4]通过融合飞行数据和气象数据,构建基于循环神经网络的航班延误预测模型;CAI Kaiquan 等^[5]将航班延误预测问题抽象为一个基于机场网络图结构信息的时间序列分析任务,并利用改进的图神经网络捕获多机场场景中高度有意义的航班延误模式。上述研究取得了一定的研究成果,但仍存在以下不足:①目前研究大多忽略机场网络上各机场间的空

间影响;②数据驱动模型的可解释性较弱,影响管制员对预测结果的接受度;③对于机场管理人员,往往更加关注机场的航班延误处于一个什么水平,且以往关于机场延误等级的研究较少。

鉴于此,笔者拟提出一种基于时空关联规则(Association Rules, AR)与 LSTM 相结合的机场进港延误等级预测模型,通过将时空关联规则作为 LSTM 模型的输入,提高延误等级预测的准确性。由于国内航班实际运行数据不对外公开,采用美国航班数据验证模型的有效性,以期提高模型的可解释性以及寻优速度。

1 机场进港延误指标及数据描述

1.1 机场进港延误指标提取

2017 年,我国民航局出台了《航班正常管理规定》,该文件明确指出,延误航班是指航班实际进港挡轮挡时间晚于计划进港时间超过 15 min 的情况^[6]。文中采用进港航班的平均延误时间,以及平均延误率 2 个指标来衡量机场进港航班的延误程度。

1) 平均延误时间是指研究时段内,所有进港航空器延误时间的平均值,计算公式如下:

$$D_{ij} = \frac{\sum_{k=1}^{N_{ij}} d_{ijk}}{N_{ij}}, d_{ijk} = \begin{cases} T_{ijk}^a - T_{ijk}^s, T_{ijk}^a - T_{ijk}^s \geq 0 \\ 0, T_{ijk}^a - T_{ijk}^s < 0 \end{cases} \quad (1)$$

式中: i, j, k 分别为第 i 机场、第 j 时段和第 k 架进港航空器; D_{ij} 为第 i 机场第 j 时段的平均延误时间, min; N_{ij} 为第 i 机场第 j 时段的进港航空器数量, 架次/h; d_{ijk} 为第 i 机场第 j 时段第 k 架航空器的进港延误时间, min; T_{ijk}^a, T_{ijk}^s 分别为第 i 机场第 j 时段第 k 架航空器的实际进港时间和计划进港时间, min。

2) 延误率是指研究时段内,延误航班的数量与该时段进港航空器数量之比,计算公式如下:

$$R_{ij} = \frac{\sum_{k=1}^{N_{ij}} \gamma_{ijk}}{N_{ij}}, \gamma_{ijk} = \begin{cases} 1, T_{ijk}^a - T_{ijk}^s \geq 15 \\ 0, T_{ijk}^a - T_{ijk}^s < 15 \end{cases} \quad (2)$$

式中: R_{ij} 为第 i 机场第 j 时段的航班延误率; γ_{ijk} 为第 i 机场第 j 时段的第 k 架航班的状态, 当航班延误超过 15 min, 则该航班处于延误状态, 其对应的 γ_{ijk} 值为 1, 否则为 0。

1.2 航班数据描述

鉴于我国航班运行数据获取困难, 从美国交通运输部网站获取得到美国 2019 年航班运行数据, 大约包含 5 000 万条航班记录。数据格式包括航班号、航班日期、实际和计划进港/离港时间、始发地和目的地等。

先进行数据预处理, 剔除大约 3% 的数据缺失航班, 以及航班取消或改航备降等造成延误超过 3 h 的航班。由于夜间凌晨航班运输量较少, 进一步选取每日 06:00—21:00 的航班运行数据作为研究数据。再基于式(1)与式(2), 计算各机场各小时的平均延误时间和延误率。

2 机场进港延误等级预测模型构建

充分挖掘与学习机场延误时空关联性成为准确预测机场延误的关键。鉴于此, 提出 AR-LSTM 的机场进港延误等级预测模型, 以实现基于机场历史延误指标数据预测未来延误等级。该模型主要由数据处理模块、延误聚类模块、规则提取模块、网络训练模块和延误预测模块构成, 如图 1 所示。

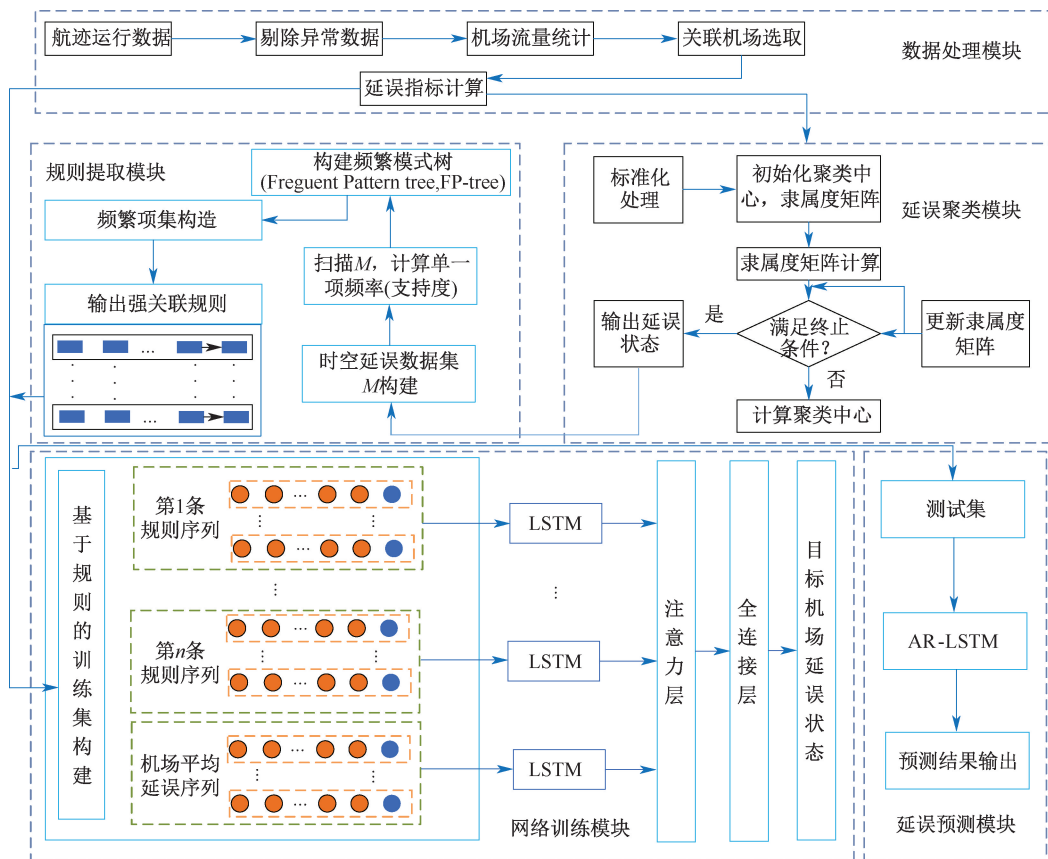


图 1 基于 AR-LSTM 的机场延误预测模型

Fig. 1 Prediction model of airport delay based on AR-LSTM

2.1 基于 FCM 的机场进港延误等级识别

机场延误等级需要同时基于平均航班延误和延误率进行识别, 并且由于空中交通系统的复杂性, 机场延误等级本身就是一个模糊的概念, 没有严格的划分标准。目前解决此类问题, 主要采用机器学习中的聚类算法, 通过描述研究对象之间的数据信息,

将研究对象划分为多个簇类, 使得同一簇内的样本数据相似性尽可能地接近, 不同簇内的样本数据相似性尽可能地大^[7]。

聚类算法主要有 K-均值聚类、谱聚类、模糊 C 均值(Fuzzy C-Means, FCM) 聚类算法和基于密度的空间聚类算法等方法, 其中, FCM 算法对运动状态

相互联系模糊、无清晰界限这一特性具有很大的优势。通过迭代使目标函数最优化得到元素隶属度矩阵,从而实现数据集的分类。

有关FCM的具体原理详见文献[8]。基于FCM的机场延误等级聚类的流程如图1 延误聚类模块所示。在进行聚类之前,由于机场平均延误时间和延误率量纲不同,需要对其进行标准化处理。聚类终止条件为达到最大迭代代数(设定为100)或低于隶属度最小变化值(设定为2)。采用肘部法则确定最佳延误等级数目^[9]。

2.2 机场进港延误时空关联规则挖掘

关联规则挖掘 Apriori 算法^[10]和FP增长(FP Growth,FP-growth)算法^[11]是常用的2种关联规则挖掘算法。Apriori 算法需要多次扫描数据库,每次利用候选频繁集产生频繁集,而FP-growth 则利用树形结构,无需产生候选频繁集而是直接得到频繁集,大大减少扫描交易数据库的次数,算法运行速度一般比Apriori快2个数量级以上。由于机场延误数据庞大,采用FP-growth 算法挖掘机场延误时空关联规则,该算法具体原理见文献[12]。

由于机场进港延误的时空分布特性,不同时段具有不同的时空关联规则。为提高规则提取的精细化以及后续延误预测的准确性,针对每个小时的延误预测都挖掘出一套相应的时空关联规则。如13:00—14:00的关联规则可理解为基于13:00之前各机场不同时段的延误等级推导出机场在13:00—14:00的延误等级。

以13:00—14:00时段关联规则的挖掘为例,给出具体步骤如下:

1) 利用各机场在9:00—14:00期间每小时的延误等级,构建机场延误时空事务集 M 。每天各机场在9:00—14:00期间不同小时的延误等级,构成一个事务。

2) 设置最小支持度和最小置信度,取值范围为0~1。

3) 扫描数据集 M ,将事务相关数据按项集频繁程度进行降序排序,构建FP-tree,并删去小于最小支持度的项。

4) 在所有频繁延误项集内部进行组合构成条件模式,将满足最小置信度的条件模式输出为强关联规则,即实现所有时空关联规则的挖掘,见表1。表中每个项目的前2位数字代表时段,中间3个字母代表机场三字代码,最后1个数字代表延误等级。

规则5的含义为:底特律大都会机场(Detroit Metropolitan Wayne County Airport,DTW)在10:00—11:00的延误等级为1(正常),洛杉矶国际机场(Los Angeles International Airport,LAX)在12:00—13:00的延误等级为2(轻度延误),奥黑尔国际机场(O'Hare International Airport,ORD)在11:00—12:00的延误等级为3(准点),置信度为91.3%。该条规则说明其他机场的延误通过传播影响到目标机场。

表1 延误传播关联规则示例

Table 1 Examples of association rules of delay propagation

序号	规则输入	规则输出	置信度
1	09DTW1	11ORD1	0.899
2	10ORD2,11MSP1, 12BWI1	12ORD2	0.931
3	09PHX1,11BWI2	12SLC1	0.856
4	10PDX1	13ORD3,13BNA1	0.911
5	10DTW1,12LAX2	11ORD3	0.913

注:机场名称分别为:明尼阿波利斯-圣保罗国际机场(Minneapolis-Saint Paul International Airport,MSP)、巴尔的摩-华盛顿国际机场(Baltimore Washington International Thurgood Marshall Airport,BWI)、菲尼克斯天港国际机场(Phoenix Sky Harbor International Airport,PHX)、盐湖城国际机场(Salt Lake City International Airport,SLC)、波特兰国际机场(Portland International Airport,PDX)、纳什维尔国际机场(Nashville International Airport,BNA)。

5) 为提高后续延误预测的计算速度,将上述关联规则中的二项集和三项集保留下来,用于后续预测。以表1为例,规则1、规则3、规则4、规则5被保留下来,规则2被删除。

6) 针对所要预测机场及预测时段,从得到的关联规则中提取预测所需的强关联规则。仍以表1为例,若要预测ORD机场在11:00—12:00的延误等级,则提取相应规则1、规则5。

2.3 基于AR-LSTM的预测模型

2.3.1 AR-LSTM模型构建

LSTM模型具有复杂的内部结构,在处理非线性问题上表现良好,被广泛应用于非线性时间序列预测问题。机场延误时间序列兼具周期性和非线性特征,因此,选择LSTM模型解决机场延误预测问题。时空关联规则能够挖掘出机场延误的时空传播特征,将时空关联规则所对应的数据信息作为LSTM的训练数据,可有效剔除冗余信息,保留有用信息,提高寻优速度和预测准确性,同时利用时空关联规则可增加预测结果的可解释性。构建AR-LSTM的预测模型步骤如下:

1) 样本集的构建。样本集主要包含2部分,一部分是基于每日机场延误数据,构建与挖掘出关联规则相一致的规则样本,另一部分是由预测机场的延误指标序列构成时序样本。以2.2节的例子说明样本集的构建。

规则样本构建。已知要预测 ORD 机场在 11:00—12:00 的延误等级,且提取的强关联规则为: 09DTW1 → 11DRD1 和 10DTW1, 12LAX2 → 11DRD3。则针对这2条规则分别构建规则样本。若完全按规则的形式建立样本进行训练,则需要先识别出规则输入项目所对应时段的机场延误等级,这样势必会降低模型预测的效率。为此,AR-LSTM 模型直接通过机场延误指标数据预测未来机场的延误等级,将规则样本的输入由延误等级转变为延误指标数据。以“10DTW1, 12LAX2 → 11DRD3”规则为例,将某日的 10:00—11:00DTW 机场和 12:00—13:00LAX 机场的平均延误时间和延误率数据(归一化后的数据)构成样本输入序列,样本输出为该日 11:00—12:00DRD 机场的延误等级。对应该条规则,假设有 m 天的历史数据,可建立 m 个样本。该例共有2条规则,则可构建 $2 \times m$ 个样本。

时序样本构建。将每天 ORD 机场 11:00 之前 4 h 的平均延误时间和延误率序列构成样本输入,样本输出为该日 11:00—12:00DRD 机场的延误等级,这样便构成一条样本。同样根据 n 天的数据可构建 n 条样本。

将上述2类样本合并,构成 ORD 机场 11:00—12:00 预测时段的样本集,样本集的输入主要包括2大类特征:每条规则对应一个规则特征,延误时序对应时变特征。

2) 训练集和测试集的划分。由 n 天得到的样本集划分为2个子集,由前 $0.8 \times n$ 天得到的样本集作为训练数据集,由后 $0.2 \times n$ 天得到的样本集作为测试数据集。

3) 将规则样本集和延误时序样本集输入到相应的 LSTM 隐藏层中,如图1的网络训练模块。将各 LSTM 的输出 h_i ,输入到注意力层,学习各条规则及延误时序的特征权重,提高网络表示能力。依据下式得到注意力向量 G_i :

$$G_i = \varphi(W_h \cdot h_i + b_h) \quad (3)$$

式中: $\varphi(x)$ 为 softmax 激活函数; W_h 为权重向量; b_h 为偏置项。依据下式将 G_i 与 h_i 作元素乘法,得到注意力层的输出:

$$\hat{h}_i = h_i \cdot G_i \quad (4)$$

将 \hat{h}_i 作为全连接层的输入,并得到最终的预测结果。

$$y_i = \sigma(W_y \cdot \hat{h}_i + b_y) \quad (5)$$

4) 根据损失函数反向传播神经网络,在此过程中更新神经元中的相关参数。通过计算损失结果是否达到预设值来判断是否满足训练迭代终止条件。

5) 迭代终止后,将模型输出,并将测试集数据输入,得出预测结果。

2.3.2 模型评价指标

采用精确率 P 、召回率 R 、 F_1 、准确率 A 以及接受者操作特性 (Receiver Operating Characteristic, ROC) 曲线5个评价指标验证 AR-LSTM 模型的预测性能。首先,将机场延误等级的多分类问题转化为每个状态等级的二分类问题;然后,若机场延误等级划分为 M 个等级,则针对每个等级均可统计出上述5个评价指标;最后,统计各指标 M 个等级的均值,表征模型的总体预测性能。定义每个延误等级发生为正类,未发生为负类。真正例 (True Positive, TP) 为把正类预测为正类,假正例 (False Positive, FP) 为负类预测为正类,真负例 (True Negative, TN) 为负类预测为负类,假负例 (False Negative, FN) 为正类预测为负类。

1) 被预测为正类中实际正类的比例 P 。

$$P = \frac{TP}{TP + FP} \quad (6)$$

2) 实际正类中被预测为正类的比例 R 。

$$R = \frac{TP}{TP + FN} \quad (7)$$

3) F_1 为 P 和 R 的加权调和平均值。

$$F_1 = \frac{2 \times P \times R}{P + R} \quad (8)$$

4) 正确分类的样本数占总样本数的比例 A 。

$$A = \frac{TP + TN}{TP + FN + FP + TN} \quad (9)$$

5) ROC 曲线:以真正例率 (True Positive Rate, TPR) 为纵轴,假正例率 (False Positive Rate, FPR) 为横轴得到的图形,TPR 表示将实际正类预测为正类的概率,FPR 表示将实际负类预测为正类的概率,为量化 ROC 曲线,计算 ROC 曲线下的面积 (Area Under Curve, AUC) 值,该值处于 0~1,值越大表明预测准确性越高。

另外,为进一步衡量错误预测的程度,统计样本的预测延误等级和实际延误等级的等级差值,并计算其均值和方差。均值越大,表明预测误差越大,预

测性能越差。方差越大,表明预测误差与均值的离散程度越大,预测性能越差。

3 延误等级预测算例分析

采用 1.2 节数据进行算例分析。由于采集数据共包含 349 个机场,且大部分机场的航班量较少,航班延误现象不明显,对其他机场延误的影响较小。为提高关联规则提取效率,选取日吞吐量排名前 30 的机场作为本算例研究的空间范围。

3.1 机场进港延误等级聚类识别

基于 FCM 聚类算法,采用 30 个机场的平均延误时间和延误率数据,聚类识别各机场不同时段的延误等级。基于肘部法确定最佳聚类数目 k 为 4,即延误等级个数为 4,聚类结果如图 2a 所示,图 2b 给出不同等级下平均延误时间箱线图。从图 2 可以看出,不同等级的箱体呈现较强的分离特征,聚类效果较好。




图 2 机场延误等级聚类结果

Fig. 2 Clustering results of airport delay levels

3.2 机场进港延误时空关联规则提取与分析

基于聚类结果构建机场延误时空事务集,采用 2.2 节机场延误时空关联规则提取方法,挖掘延误传播演化轨迹,共得到 630 条关联规则。其中,比较

设置不同数值时 AR-LSTM 模型的预测效果,并选取预测效果最好时所对应的参数取值,即最小支持度为 0.3,最小置信度为 0.75。选取 3 条规则(规则中在本文第一次出现的机场有:圣弗朗西斯科国际机场(San Francisco International Airport, SFO)、华盛顿杜勒斯国际机场(Washington Dulles International Airport, IAD))并对其进行可视化,如图 3 所示。

规则 a: (14DTW1, 15IAD1, 15SFO2) \rightarrow 16MSP1);

规则 b:(15ORD2,16MSP1) \rightarrow (19ORD3);

规则 c: (14DTW1) \rightarrow (15IAD1, 16MSP1, 19SLC1)。

图 3 中矢量线 income、internal 表示 3 种不同的延误传播方向, income 线代表关联机场对目标机场延误等级的影响, internal 线代表目标机场对自身延误等级的影响。从规则 2 可以看出,目标机场的延误情况不仅与关联机场有关,也与自身延误情况有关。ORD 机场在 15:00—16:00 时段的延误状况会影响到该机场 4 h 之后的延误状况。




图 3 时空关联规则可视化

Fig. 3 Visualization of spatio-temporal association rules

3.3 机场进港延误等级预测结果及分析

基于关联规则挖掘结果,预测机场的进港延误等级。分别分析不同延误等级、不同时段和不同机场的预测准确性,并和现有基线模型进行对比,验证 AR-LSTM 模型的有效性。

3.3.1 模型参数设置

经过多次迭代调优最大迭代次数、网络层数、层节点数、学习率、权值初始化等参数,并选取模型预测效果最好时所对应的参数值,作为最终的参数取值。经过调优试算发现,选用 Adam 优化器,均方误差损失函数的学习率为 0.001,最大迭代次数为 200,批处理量为 64,LSTM 隐藏层数为 3 时,模型预测效果最好。

3.3.2 不同延误等级的预测结果分析

以 ORD 机场 2019 年 10 月 1 日—12 月 31 日每天 19:00—20:00 时段的延误等级预测结果为例,分

析不同等级的预测效果,计算不同等级下的 P 、 R 、 F_1 和 A ,见表 2。可见:模型的总体准确率和稳定性较高, A 和 F_1 分别达到 0.91 和 0.89。其中,轻度延误的 A 最低,为 0.81,重度延误的 A 最高,为 1,这可能是由于重度延误的延误指标均明显高于其他延误等级,分离度较大,易于模型对该等级的识别。

表 2 性能指标

Table 2 Performance indicators

延误等级	P	R	F_1	A
正常	0.92	1	0.96	0.92
轻度延误	0.76	1	0.86	0.81
中度延误	1	0.58	0.72	0.92
重度延误	1	1	1	1
平均值	0.92	0.90	0.89	0.91

3.3.3 不同时段的预测结果分析

通过单一时段的预测结果说明 AR-LSTM 模型的有效性。进一步以 ORD 机场为例,分析其在不同时段的预测效果,部分时段的预测效果见表 3。可见:各时段的总体预测效果较好, A 均在 80% 以上,尽管 19:00—20:00 的预测准确率较低,但其延误等级预测误差较小,不足 0.2。

表 3 不同时段预测结果分析

Table 3 Analysis of prediction results in different periods


时段	D/min	$R/\%$	$A/\%$	平均预测误差/ min
11:00—12:00	3.075	4.27	95.8	0.041
14:00—15:00	4.028	5.66	91.7	0.093
16:00—17:00	5.013	6.85	86.5	0.145
19:00—20:00	6.412	7.35	83.3	0.197

3.3.4 不同预测模型的对比分析


为说明 AR-LSTM 模型的优越性,同时进行支持向量机(Support Vector Machine, SVM)和 LSTM 模型的对比试验,以及 AR-LSTM 模型中未考虑延误时序特征(只考虑规则特征)的试验(AR-LSTM-R),各模型的 ROC 曲线和 AUC 值如图 4 所示,各模型的 P 、 R 、 F_1 、 A 见表 4。由表 4 可知:AR-LSTM 模型的各个评价指标都明显优于其他 3 个模型,相比其他模型,AR-LSTM 模型各延误等级的 ROC 曲线都更加接近左上角,4 种方法的整体 AUC 值分别为:SVM: 0.845; LSTM: 0.840; AR-LSTM-R: 0.8325; AR-LSTM:0.905。可见:AR-LSTM 的 AUC 值最高,同样说明 AR-LSTM 模型预测效果的优越性。

3.3.5 预测结果的解释


网络训练以后,通过注意力机制获取不同特征



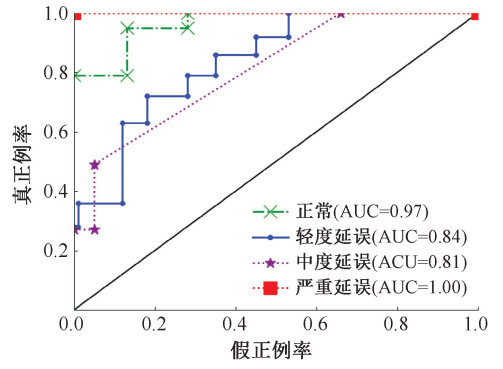
(a) SVM



(b) LSTM



(c) AR-LSTM-R



(d) AR-LSTM

图 4 ROC 曲线

Fig. 4 ROC curves

的连接权重,即不同特征对最终预测结果的影响程度。仍以 ORD 机场 14:00—15:00 时段延误等级预测为例,该预测共用到 3 个关联规则,因此,共有

表4 不同模型性能指标

Table 4 Performance indicators of different models

模型	P	R	F_1	A
SVM	0.86	0.82	0.81	0.88
LSTM	0.80	0.79	0.76	0.87
AR-LSTM-R	0.75	0.76	0.72	0.87
AR-LSTM	0.92	0.89	0.89	0.91

3个规则特征和1个时序特征。提取模型训练后注意力层连接各特征LSTM的权重,见表5。从表5中可以看出,3个规则中规则1的权重最大,说明ORD机场14:00—15:00时段的延误等级受规则1影响最为严重,即延误情况与DTW机场14:00—15:00和ORD机场15:00—16:00时段的延误情况密切相关。

表5 特征权重值

Table 5 Weights of features

序号	特征	权重
1	规则1:14DTW1,15ORD2→19ORD2	0.27
2	规则2:15ORD2,16MSP2→19ORD3	0.11
3	规则3:18ORD3,18DTW4→19ORD4	0.18
4	时序:15ORD,16ORD,17ORD,18ORD→19ORD	0.44

4 结论

1) 根据机场进港航班延误的时空关联特征,将时空关联规则挖掘与深度预测相结合,构建基于AR-LSTM的机场进港延误等级预测模型,对比不同延误等级、不同时间段的预测效果。结果表明:AR-LSTM模型预测的总体准确率和稳定性较高。

2) 相对于SVM、LSTM和AR-LSTM-R等预测模型,对于不同等级的延误预测,AR-LSTM模型均具有更高的预测准确率。

3) FP-Growth算法能够很好地挖掘出不同机场不同时段延误等级之间的相关性,将关联规则输入到预测算法中,有效提高预测准确性和训练速度,且可解释预测结果。

4) 未考虑天气、流控等因素,一方面由于这些数据难以获取到;另一方面,由于延误时间序列也是这些影响因素综合作用的结果,AR-LSTM模型通过学习各机场延误时间序列的时空演化特征,实际上也是在间接学习这些因素的综合影响特征,并取得较为满意的预测效果。后续在数据可获取的情况下,会将更多的航班延误影响因素,如天气、流控等数据,考虑到预测模型中,以提高预测精度。

参考文献

- [1] 中国民用航空局. 2019年民航行业发展统计公报[R]. 2020.
- [2] 岳仁田,韩蒙. 基于四诊法的管制席安全运行状态诊断[J]. 中国安全科学学报, 2021, 31(9): 52-59.
YUE Rentian, HAN Meng. Diagnosis of safety operation state for ATC position based on four diagnostic methods[J]. China Safety Science Journal, 2021, 31(9): 52-59.
- [3] KIM Y J, CHOI S, BRICENO S, et al. A deep learning approach to flight delay prediction[C]. AIAA 35th Digital Avionics Systems Conference, 2016: 1-6.
- [4] QU Jingyi, ZHAO Ting, YE Meng, et al. Flight delay prediction using deep convolutional neural network based on fusion of meteorological data[J]. Neural Process Letters, 2020, 52(7): 1-10.
- [5] CAI Kaiquan, LI Yue, FANG Yiping, et al. A deep learning approach for flight delay prediction through time-evolving graphs[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(8): 11 397-11 407.
- [6] CCAR-300-2017, 航班正常管理规定[Z].
- [7] 王丙参,魏艳华,张贝贝. 基于多元数据的谱聚类算法改进与聚类个数确定[J]. 统计与决策, 2022(12): 1-7.
WANG Bingcan, WEI Yanhua, ZHANG Beibei. Improvement of multivariate data-based spectral clustering algorithm and determination of the number of clusters[J]. Statistics and Decision, 2022(12): 1-7.
- [8] 余曼,赵轩,魏朗,等. 基于FCM聚类算法的电动车城市循环工况构建[J]. 公路交通科技, 2018, 35(10): 140-149.
YU Man, ZHAO Xuan, WEI Lang, et al. Construction of electric vehicle urban driving cycle based on FCM clustering algorithm[J]. Journal of Highway and Transportation Research and Development, 2018, 35(10): 140-149.
- [9] 姜丁菊,刘学文,姜晓雪. 基于聚类的恐袭事件嫌疑人与可疑据点预测[J]. 重庆工商大学学报:自然科学版, 2019, 36(3): 18-23.
JIANG Dingju, LIU Xuewen, JIANG Xiaoxue. Cluster-based terrorist attack suspects and suspicious base prediction[J]. Journal of Chongqing Technol & Business University: Natural Science Edition, 2019, 36(3): 18-23.
- [10] AGRAWAL R, IMIELINSKI T, SWAMI A. Mining association rules between sets of items in large databases[C]. ACM SIGMOD Conference on Management of Data, 1993: 1-10.
- [11] PARK J S, CHEN M S, YU P S. An effective hash-based algorithm for mining association rules[J]. ACM SIGMOD Record, 1995, 24(2): 175-186.
- [12] 王艾迪,邢莹莹,张诗雯,等. 基于关联规则的危险品公路运输事故风险因素研究[J]. 中国安全科学学报, 2023, 33(6): 159-165.
WANG Aidi, XING Yingying, ZHANG Shiwen, et al. Research on risk factors of hazardous material highway transport accidents based on association rules[J]. China Safety Science Journal, 2023, 33(6): 159-165.

作者简介: 李善梅 (1982—),女,天津人,博士,副教授,主要从事空中交通运输规划与管理方面的研究。
E-mail: sm-li@cauc.edu.cn.