

城市轨道交通突发事件风险等级判别方法

范博松^{1,2}, 邵春福^{2,3}

(1. 中国人民公安大学 交通管理学院, 北京 100038; 2. 北京交通大学 综合交通运输大数据应用技术交通运输行业重点实验室, 北京 100044; 3. 新疆大学 交通运输工程学院, 乌鲁木齐 830046)

摘要:为提升风险等级判别的准确性, 破解城市轨道交通系统风险实时管控和事件应急处理的关键问题, 构建了改进的特征选择算法(Im-F-score+XGB)对突发事件风险因素的特征进行筛选, 通过分析城市轨道交通突发事件的基础数据, 计算各风险特征的重要度, 挖掘不同特征对突发事件风险等级的影响程度, 得到突发事件风险等级判定的重要特征; 同时, 采用多时间窗循环扫描方法和加权级联残差森林模型相融合的思路, 获得突发事件风险等级与风险特征的映射关系, 建立了改进的突发事件风险等级判别模型(Im-F-GCF)。通过与 RF、HGBDT、GCF、LightGBM 4 个代表模型对比分析, 显示出本文提出的 Im-F-GCF 模型的有效性。

关键词: 交通运输规划与管理; 城市轨道交通; 突发事件; 风险等级; 特征选择; 加权级联残差森林

中图分类号: U121 文献标志码: A 文章编号: 1671-5497(2024)02-0427-09

DOI: 10.13229/j.cnki.jdxbgxb.20220352

Urban rail transit emergency risk level identification method

FAN Bo-song^{1,2}, SHAO Chun-fu^{2,3}

(1. School of Traffic Management, People's Public Security University of China, Beijing 100038, China; 2. Key Laboratory of Transport Industry of Big Data Application Technologies for Comprehensive Transport, Beijing Jiaotong University, Beijing 100044, China; 3. School of Transportation Engineering, Xinjiang University, Urumqi 830046, China)

Abstract: In order to promote the accuracy of risk level identification, to solve the real-time risk control and emergency treatment problems of urban rail transit system, an improved feature selection algorithm (Im-F-score+XGB) on filtering features of the risk factors for emergencies was proposed. Through the analysis of the basic data of urban rail transit emergency, the feature importance degree of each risk feature was calculated, the influence degree of different features on the risk of emergencies was excavated, and the important features for determining the risk level of emergencies was obtained. Besides, the cyclic multi-time window scanning method and the weighted cascade residual forest model were used to obtain the mapping relationship between the emergency risk grade and the feature of risk features, and an improved

收稿日期: 2022-03-31.

基金项目: 国家重点研发计划“交通载运装备与智能交通技术”重点专项项目(SQ2023YFB4300098); 国家自然科学基金基金项目(52072025).

作者简介: 范博松(1996-), 男, 博士研究生. 研究方向: 交通安全. E-mail: fanbosong@bjtu.edu.cn

通信作者: 邵春福(1957-), 男, 教授, 博士. 研究方向: 交通安全. E-mail: cfshao@bjtu.edu.cn

emergency risk level identification model (Im-F-GCF) was established. Compared with RF, HGBDT, GCF and LightGBM models, the validity of the proposed model is verified.

Key words: transportation planning and management; urban rail transit; emergency; risk level; feature selection; weighted cascade residual forest

0 引言

随着世界上各大城市大规模轨道交通网路的兴建,城市轨道交通的运营与管理安全问题也日益凸显。部分学者使用聚类分析、贝叶斯理论等传统机器学习方法^[1-5]对突发事件影响因素进行分析。郑宣传等^[6]提出了一种改进的城市轨道交通突发事件 K 均值聚类方法。利用聚类分析、主成分分析方法提取4个主成分变量,并计算推导出原始变量的权重系数,通过分析突发事件不同状态,为地铁运营的风险防控提供了指导。然而,传统机器学习方法侧重于突发事件影响因素的标定,对于影响因素与风险状态作用关系的探究相对薄弱。

随着深度学习技术的快速发展,使深入挖掘突发事件数据特征与属性之间的关系成为可能^[7-9]。Paltrinieri等^[10]采用深度学习模型对突发事件外部环境特征和内部系统特征与不同后果状态的相关关系进行了分析。结果表明,DNN对作用关系判定的准确性较高,并且在克服风险评估挑战方面具有普遍适用性。然而,深度学习模型依赖大量样本进行深层的训练,在面对小样本数据时,往往因过拟合而无法取得较好的评价效果。

为了分析基于小训练样本的研究,Zhou等^[11]在吸收深度学习优势的基础上提出了深度森林模型,部分学者^[12-15]将其成功地应用于解决事故故障后果的分类与预测问题;李志慧等^[16]引入极端梯度提升算法筛选事故特征,将筛选出的重要事故特征作为改进的深度森林模型的输入。通过对比分析,验证了模型预测交通运行风险状态等级的有效性。然而,深度森林模型的研究集中在分析特定类型的故障状态,且鲜有研究针对城市轨道交通系统的突发事件进行分析。

为了探究基于小训练样本的城市轨道交通系统多维风险因素与突发事件风险等级的关系,本文通过融合改进的Im-F-score算法与XGB算法,筛选出与风险等级相关性强的风险因素;采用

深度森林的多层级联分析模式,提出了包含循环多时间窗扫描和加权级联残差森林两个模块的改进的深度森林模型(Im-GCF),两部分共同构建起风险等级判别模型(Im-F-GCF)。同时,以轨道交通路网每日因突发事件而产生的“列车调整”总量作为突发事件风险等级的划分标准,进行风险等级的判别,并与其他模型进行对比,验证了模型的有效性。

1 突发事件风险等级判别模型

1.1 模型框架

本文以深度森林模型(Multi-grained cascade forest, GCF)作为等级预测模型主体,通过增加特征选择模型并改进GCF模型结构,构建了突发事件风险等级判别的Im-F-GCF模型。采用改进的F-score算法(Im-F-score),通过对比特征的重要度排序,筛选出最优特征子集输入Im-GCF模型;采用循环多时间窗扫描方法对输入的特征子集进行多维度切片,合并具有不同特征关联信息的切片并输入加权级联残差森林,通过逐层计算得到突发事件风险等级预测结果 r 。模型框架如图1所示。

1.2 Im-F-score+XGB特征选择模型

城市轨道交通突发事件数据包含的风险因素众多,其中部分因素与突发事件风险等级的判别无关或者仅存在较小的相关性,会对判别模型的性能产生不良影响,因而需要对风险因素进行特征筛选来提升判别模型的性能。

特征选择领域有3大类方法,分别为过滤法、包装法和嵌入法。其中,过滤法作为传统方法,有着不依赖于机器学习方法、不需要交叉验证、计算效率比较高等优点;嵌入法具有包装法与机器学习算法相结合的优点,且计算效率也相对较高。为了融合3类方法的优点,本文采用过滤法Im-F-score和嵌入法XGB结合的思路进行特征选择。

1.2.1 Im-F-score特征选择模型

传统的F-score算法适用于二分类的特征值计算,为了对多分类问题进行研究,引入改进的

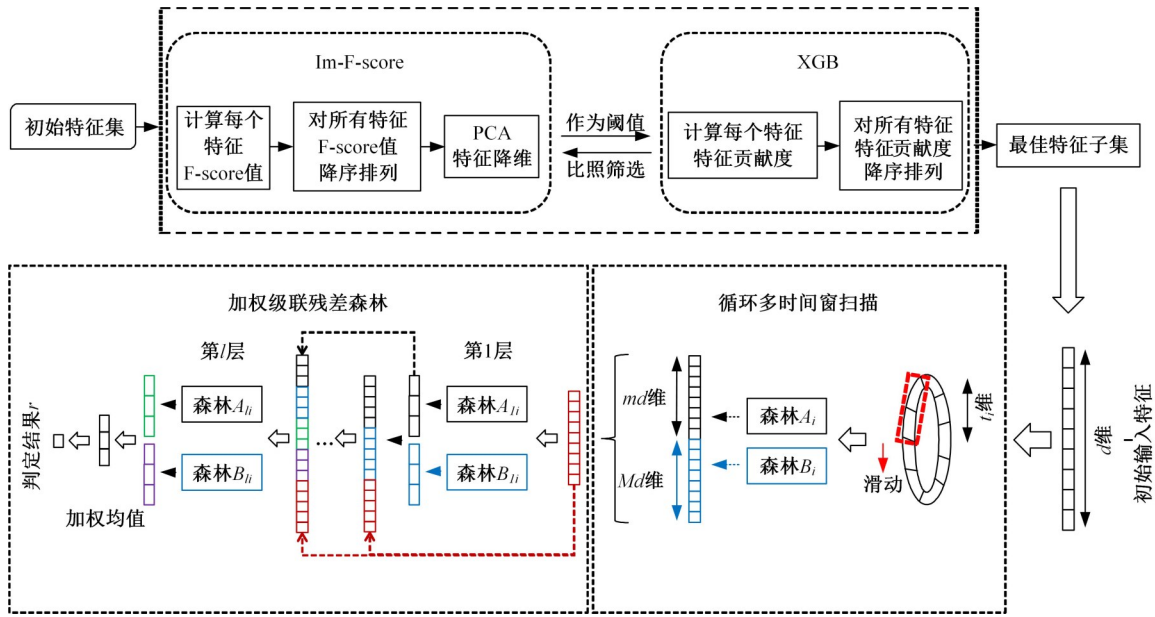


图 1 Im-F-GCF 判别模型框架

Fig. 1 Im-F-GCF model framework

Im-F-score 算法,具体描述如下。

突发事件训练样本集为 $\{x_k \in R^m | k = 1, 2, \dots, n\}$; $l (l \geq 2)$ 为突发事件风险等级分类的数目, $n_j (j = 1, 2, \dots, l)$ 为第 j 类样本的数量, 则训练样本集中第 i 个风险特征的 F-score 值为:

$$F_i = \frac{\sum_{j=1}^l (\bar{x}_i^{(j)} - \bar{x}_i)^2}{\sum_{j=1}^l \frac{1}{n_j - 1} \sum_{k=1}^{n_j} (x_{k,i}^{(j)} - \bar{x}_i^{(j)})^2} \quad (1)$$

式中: \bar{x}_i 为第 i 个风险特征在整个数据集上的平均值; $\bar{x}_i^{(j)}$ 为第 i 个风险特征在第 j 类数据集上的平均值; $x_{k,i}^{(j)}$ 为第 k 个样本点的第 i 个风险特征在第 j 类数据集上的特征值。

得到各风险特征的 F-score 值后,按照数值大小由高到低对其进行逆序排列。同时,为了确定所要选择的特征个数,借鉴主成分分析(Principal component analysis, PCA)的操作方法进行特征降维。通过计算逆序排列特征的累计贡献度,设定主成分选择区间的临界值 α 和 β ,将特征的累计贡献度划分为 $[0, \alpha]$ 、 $[\alpha, \beta]$ 和 $[\beta, 100\%]$,保留累积贡献度在 $[\alpha, \beta]$ 的特征,实现重要特征筛选。

1.2.2 XGB 特征选择模型

极端梯度提升算法(eXtreme gradient boosting, XGB)是一种基于决策树的树模型,决策树生长的过程体现了特征子集不断被搜索、被使用的

过程,因而可以应用训练后的决策树模型来输出特征的重要性。

一般来说,特征的重要性表示这个特征在构建决策树的过程中所起到的作用。如果一个特征在所有树中被用来进行属性划分的次数越多,那么该特征就越重要,且贡献度就越高。对不同的决策树来说,每个特征作为属性分割点对模型性能改进的程度不同,则由改进程度计算单个决策树的重要性,并依据属性分割点被使用的次数进行加权。性能度量可以使用具体的误差函数等进行刻画。计算模型中所有决策树的特征贡献度,得到特征贡献度的排序。各个特征的贡献度可以用式(2)简化表示。

$$Cont_i = K_i \frac{N_i}{f_i}, i = 1, 2, \dots, n \quad (2)$$

式中: N_i 为第 i 个风险特征作为属性分割点被使用的次数; f_i 为第 i 个风险特征对模型性能的改进程度; K_i 为第 i 个风险特征贡献度的系数。

将 Im-F-score 模型初步筛选出的风险特征个数作为 XGB 模型的特征数量阈值,利用 Im-F-score 模型与 XGB 模型分别提取风险特征,比照两个模型得到的特征排序,选取贡献度排序都靠前的特征作为最终的特征选择结果。

1.3 Im-GCF 等级判别模型

深度森林模型(GCF)与神经网络模型类似,采用多级多层结构进行非线性映射,以此提高模型的代表学习能力和泛化能力。GCF 模型主要

分为多粒度扫描和级联森林两个阶段:①多粒度扫描森林通过特征转换重组原始样本的特征;②级联森林通过逐层学习特征来进行分类。

本文对GCF模型以上两个阶段进行改进,设计用于增强原始样本特征重组的循环多时间窗扫描模块和用于提升分类效果的加权级联残差森林模块,融合这两个模块,构建起Im-F-GCF模型。

1.3.1 循环多时间窗扫描

原始突发事件样本的风险特征为 d 维,GCF模型通过设定某一维度 t 的时间窗进行扫描,将 $d-t+1$ 维的扫描结果输入随机森林网络进行后续的特征重组。本文通过设定多时间窗向量 $T=\{t_1, t_2, \dots, t_n\}$,采用多种维度的时间窗对原始样本进行切分,得到 n 组不同原始样本特征切片。同时,为了避免因首尾数据仅被扫描一次而产生偏差,将原始样本数据首尾相接,形成了多维的圆环。在多维特征圆环中,任意的时间窗 t_i 可以从首个特征维度开始扫描,直到 d 次的扫描任务结束,据此得到 $t_i \times d$ 维的特征切片组合。相较于 $d-t+1$ 维的扫描结果, d 维的特征切片能够更有效地体现首尾特征以及不同维度特征组合的关联信息。

设定目标风险等级分类为 $C=\{c_1, c_2, \dots, c_m\}$,将 $t_i \times d$ 维的特征切片输入森林模型 A_i 和森林模型 B_i ,每个森林模型对输入特征进行训练,输出 $d \times m$ 的表征矩阵,分别对应不同样本数据为 c_i 类等级的概率。合并两个森林模型训练得到的输出矩阵,得到不同时间窗处理的子样本所对应的 $2 \times d \times m$ 维特征向量。依次连接 n 个子样本处理得到的特征向量,形成 $\sum_{i=1}^n 2 \times t_i \times d \times m$ 维的高维向量,并将这一输出结果作为后一阶段加权级联森林模块的输入。

1.3.2 加权级联残差森林

GCF模型的级联森林模块是由多层森林模型集成的决策树结构。现有的多层次的机器学习模型存在随着层数增加出现梯度爆炸或梯度消失的问题。为避免在级联森林模块出现此类问题,将类似残差连接的结构应用于级联森林模块,即通过拼接级联森林各层级的原始输入特征与其上一层级的输出特征来作为本层级的输入,以此确保模型的预测效果不会随着层数的增加而下降。

此外,级联森林的预测模式为对最后一层级

每个森林模型生成的类概率向量取均值,并根据计算结果确定最终类别。对每个森林模型取均值即为对其所包含的所有决策树的预测结果取均值,由于每个决策树对同一个样本的预测效果不同,对预测结果直接取算数均值将产生较大误差,因此本文采用加权均值确定最终的预测结果。

设每个森林模型有 k 棵决策树, k 棵决策树对各样本的预测结果表示为矩阵 P 的形式:

$$P = \begin{bmatrix} p_{11} & p_{12} & \cdots & p_{1c} \\ p_{21} & p_{22} & \cdots & p_{2c} \\ \cdots & \cdots & \cdots & \cdots \\ p_{k1} & p_{k2} & \cdots & p_{kc} \end{bmatrix} = [p_1, p_2, \dots, p_c]$$

风险等级为 r 级的样本对应的预测结果为 $[p_{1r}, p_{2r}, \dots, p_{kr}]^T$,每个决策树的权重表示为:

$$w_i = \frac{p_{ir}}{\sum_{i=1}^k p_{ir}}, r = 1, 2, \dots, c \quad (3)$$

进而每个森林模型的预测结果为:

$$P = [p_1, p_2, \dots, p_c] = \left[\sum_{i=1}^k w_i p_{i1}, \sum_{i=1}^k w_i p_{i2}, \dots, \sum_{i=1}^k w_i p_{ic} \right] \quad (4)$$

2 实验分析

2.1 数据处理

本文突发事件的基础数据来源于2017~2018年北京市轨道交通路网的影响行车情况数据,包括日路网客运量、实际开行列数、列车兑现率、列车正点率、天气状况、各条线路满载率等30个突发事件风险特征以及停运列车数(停运)、通过列车数(通过)、清人列车数(清人)、掉线列车数(掉线)和中途折返列车数(中折)这5个表征突发事件对列车运行影响程度的指标。其中,这30个突发事件风险因素主要来自于列车实际运营情况、列车晚点情况、各条线路的断面满载率以及环境因素这4个大的方面。列车实际运营情况包括实际开行列数、列车兑现率、延误时长等;列车晚点情况包括2分晚点列数、正点率等;环境因素包括路网客运量、节假日与否、天气状况等。从这30个特征入手分析轨道交通风险因素对突发事件风险等级的影响,具体特征如表1所示。将停运、通过、清人、掉线以及中折这5个列车调整指标合并,作为突发事件风险等级的评价指标。某日5个指标的具体数值如表2所示。

表 1 30 个风险特征描述

Table 1 30 risk features and their descriptions

变量名称	变量描述
日路网客运量/万人次	每日轨道交通路网客运量
实际开行列车数/列	每日路网实际开行列车数
列车兑现率/%	每日路网实际与计划开行列车比值
延误时长/min	每起突发事件延误时间长度
2分晚点列车数/列	每日路网晚点超过 2 min 的列车数
正点率/%	每日路网实际开行列车正点到达比率
加开临客列车/列	每日路网加开临时列车数量
工作日	工作日、非工作日取值:0、1
天气	恶劣天气、非恶劣天气取值:0、1
线路	突发事件所发生的线路
专业类别	突发事件所属的类别(信号故障、车辆故障等)
1号线断面满载率/%	
2号线断面满载率/%	
5号线断面满载率/%	
6号线断面满载率/%	
7号线断面满载率/%	
8号线断面满载率/%	
9号线断面满载率/%	
10号线断面满载率/%	
13号线断面满载率/%	
15号线断面满载率/%	每日高峰时段各条线路断面满载率平均值
昌平线断面满载率/%	
房山线断面满载率/%	
亦庄线断面满载率/%	
八通线断面满载率/%	
机场线断面满载率/%	
4-大兴线断面满载率/%	
14号线(西段)断面满载率/%	
14号线(东段)断面满载率/%	
16号线断面满载率/%	

不同的突发事件会对路网列车的运行产生不同的影响程度,因而也对应着不同的列车调整情况。本文将轨道交通路网突发事件当日列车调整的数值大小作为突发事件风险等级的划分标准,对发生突发事件当日的路网线路停运、通过、清人、掉线及中折次数进行聚类分析。聚类结果表明,可以将轨道交通路网突发事件风险等级划分为 1~6 级,代表路网当天“列车调整”的数量分别落在区间 [0, 4], [5, 15], [16, 30], [31, 60], [61, 120], [121, +∞)。将 30 个风险特征中的

表 2 某日路网及各条线路列车调整的数量

Table 2 Number of train adjustments to the network and each line on a given day

运营企业及线路	列车调整				
	停运	通过	清人	掉线	中折
路网	8	1	8	4	6
1号线					
2号线					
5号线	1			2	
6号线	7	1	6		6
7号线					
8号线					
9号线					
北京地铁 10号线			2	2	
13号线					
15号线					
昌平线					
房山线					
亦庄线					
八通线					
机场线					
S1线					
小计	8	1	8	4	6
4-大兴线					
京港地铁 14号线(西段)					
14号线(东段)					
16号线(北段)					
小计					

分类变量进行独热编码(One-Hot),数值变量进行归一化处理,以此作为初始特征集输入模型。

2.2 风险因素特征重要度分析

将 30 个指标处理得到的初始特征集代入 Im-F-score 模型,计算得到各指标的特征重要度分数。同时,用各指标的分数除以分数总和,计算出各指标的特征贡献度,将各特征计算得到的贡献度转化为百分比,逆序排列并累加得到累积百分比贡献度,如图 2 所示。

根据计算结果与主成分分析对累积特征百分比贡献度临界值的常用取法^[16],这里取 $\alpha=88\%$, $\beta=96\%$,共包含特征重要度较高的 10 个风险因素指标,如图 2 中虚线框所示。

将数据代入 XGB 模型输出结果并对特征进行排序后,以 Im-F-score 筛选得到的特征个数作为阈值,对比 XGB 模型与 Im-F-score 模型得到的特征重要度排序,得到 7 个相同的风险特征。相较于单独利用 Im-F-score 或 XGB 模型选定的




图2 突发事件特征重要度与累积贡献度 (Im-F-score 模型)

Fig. 2 Importance and cumulative contribution of emergency features (Im-F-score model)

特征变量进行下一步的模型训练,将二者结合既能通过减少特征个数来简化后续模型的计算复杂度,也能强化关键特征在风险分析中的重要作用。

本文将这7个重要风险特征作为特征变量用于判别后续突发事件风险等级。具体特征如表3所示,可知,突发事件所包含的列车实际运营情况的4个特征和各条线路断面满载率的3个特征与突发事件的产生以及所导致的后果严重程度都有较强相关性。分析城市轨道交通运营数据可知,不论是日路网客运量越大,还是实际开行列车的数量与计划开行列车的数量相差越大,或是列车延误时间越长,都表明有较为严重突发事件产生。机场线、4-大兴线、16号线作为连接城区核心地区与边界地区的线路,在遇到较高的乘客压力,即当日的断面满载率较高时,也容易出现突发状况。总的来说,城市轨道交通系统每日的实际运营情况越不理想、线路满载率越高,越容易发生风险等级高的突发事件。

2.3 模型评价指标

本文采用准确率 Accuracy(*Acc*)、精确度 Pre-

表3 重要风险特征

Table 3 Important risk features

变量名称	变量描述
日路网客运量	每日轨道交通路网客运量
实际开行列车数	每日轨道交通运营管理部门实际开行列车数
列车兑现率	每日路网实际开行列车数与计划开行列车数比值
延误时长	突发事件从产生影响到影响结束的持续时间
机场线断面满载率	每日高峰时段各条线路断面满载率平均值
4-大兴线断面满载率	
16号线断面满载率	

cision(*Pre*)、召回率 Recall(*Rec*)、特异度 Specificity(*Spe*)、F1值、Kappa系数(*Kap*)这6个数值指标以及ROC曲线共7个指标对模型的判别能力进行评价。对每个风险等级的突发事件,定义当前突发事件的风险等级为正类,非当前突发事件的风险等级为负类。如果模型的判别结果与当前突发事件的风险等级一致,那么就用 *TP* 来表示,即正类被判别为正类。同理,如果模型的判别结果与当前突发事件的风险等级不一致,那么就用 *FN* 来表示,即正类被判别为负类;如果模型的判别结果与非当前突发事件的风险等级一致,那么就用 *TN* 来表示,即负类被判别为负类;如果模型的判别结果与非当前突发事件的风险等级不一致,那么就用 *FP* 来表示,即负类被判别为正类。风险等级判别结果的分类矩阵如表4所示。用 *Acc* 表示模型判别结果的分类与其原始分类一致的样本在总样本中所占的比重;*Pre* 表示模型的判别结果为正类的样本中真正类所占的比重;*Rec* 表示真正类的样本中模型的判别结果为正类所占的比重;*Spe* 表示真负类的样本中模型的判别结果为负类所占的比重;*F1* 表示 *Pre* 和 *Rec* 的加权调和平均数;*Kap* 系数与以上的度量指标不同,它是一种用于衡量分类精度的指标,代表现有分类与完全随机分类产生错误所减少的比重;ROC曲线表示在真正类或真负类的样本中,判别结果为正类的分布情况的图形,其中,横轴为真负类被判别为正类所占的比重,用 *FPR* 表示,纵轴为真正类被判别为正类所占的比重,用 *TPR* 表示。因为突发事件的风险等级被分为6级,所以上指标取各个等级的判别平均值进行计算。式(5)~(10)为6个数值评价指标的具体计算方法。

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

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

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

表4 各风险等级判别结果的分类矩阵

Table 4 Classification matrix of prediction results of each risk level

实际情况	判别结果	
	正类	负类
正类	<i>TP</i>	<i>FN</i>
负类	<i>FP</i>	<i>TN</i>

$$Spe = \frac{TN}{TN + FP} \quad (8)$$

$$F1 = \frac{2 \times Pre \times Rec}{Pre + Rec} \quad (9)$$

$$Kap = \frac{P_o - P_e}{1 - P_e} \quad (10)$$

式中: P_o 为每一类正确分类的样本数量之和占总样本数的比重,也就是准确率 Acc_o 。

$$P_e = \frac{a_1 \times b_1 + a_2 \times b_2 + \dots + a_n \times b_n}{n \times n} \quad (11)$$

假设每一类的真实样本个数分别为 a_1, a_2, \dots, a_n , 而判别出的每一类的样本个数分别为 b_1, b_2, \dots, b_n , 总样本个数为 n 。

ROC 曲线横轴和纵轴变量的计算方法如下:

$$TPR = \frac{TP}{TP + FN} \quad (12)$$

$$FPR = \frac{FP}{TN + FP} \quad (13)$$

2.4 模型结果评价

将 2017~2018 年共 3426 条样本的突发事件数据(日路网客运量、实际开行列数以及延误时长等 7 个特征对应的数据)以 8:2 的比例随机组合, 分别作为训练集和测试集输入 Im-F-GCF 模型中进行训练和测试, 计算得到模型评价指标对应的一系列数值和 ROC 曲线。为比较分析, 本文同时选择 RandomForest (RF)、HGBDT、GCF 及 LightGBM 模型进行对比实验, Im-F-GCF 模型的训练结果以及各模型的测试结果如表 5 所示, Im-F-GCF 模型训练结果以及各模型测试结果的 ROC 曲线如图 3 所示。

由表 5 可知, Im-F-GCF 模型训练结果和测试结果的 Acc 分别达到 90.86%、89.70%, 展现出模型具有良好的判别效果, 且横向对比来看, 其优于另外 4 个模型。Im-F-GCF 模型的 Pre 、 Rec 和 $F1$ 都能达到较高的程度, 且优于其他模型, 但判别结果对应的 Spe 效果相对而言不甚理想, 且弱


表 5 实验结果

Table 5 Experimental results


模型		Acc/ %	Pre/ %	Rec/ %	Spe/ %	F1/ %	Kap/ %
Im-F-GCF	训练	90.86	94.76	93.13	83.70	93.94	87.78
GCF	测试	89.70	93.77	92.50	81.07	93.13	86.24
RF		84.50	89.76	88.71	73.47	89.23	79.59
HGBDT		86.25	90.77	90.73	73.30	90.75	81.76
GCF		88.24	92.59	91.69	77.76	92.14	84.40
Light GBM		88.65	93.58	91.05	81.52	92.30	84.88

于 LightGBM 模型, 说明模型对正类的判别能力较强, 对负类的判别能力仍有待提升。Im-F-GCF 模型分类精度指标 Kap 落在 0.8~1 之间, 反映出 6 个风险等级分类的一致性较强。

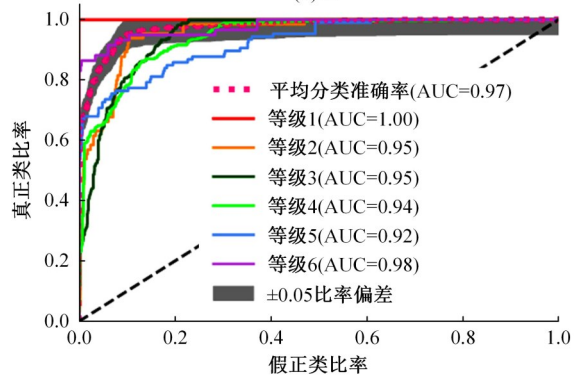
由图 3 可知, Im-F-GCF 模型整体的 ROC 曲



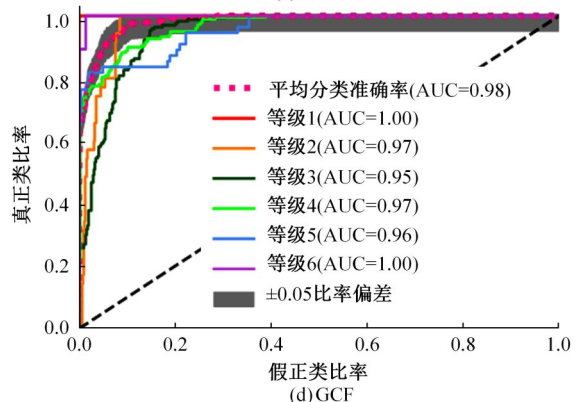
(a) Im-F-GCF 训练结果



(b) RF



(c) HGBDT



(d) GCF




图3 各模型ROC曲线图

Fig. 3 ROC curves of each model

线以及各个分类的ROC曲线都非常趋向于左上角,同样显示出模型良好的判别性能,且模型整体的AUC值达到0.99。横向对比来看,虽然其余4个模型个别分类的AUC值能与Im-F-GCF模型持平,但整体的AUC值仍有差距,表明Im-F-GCF模型整体的性能优于RF、HGBDT、GCF和LightGBM这4个模型。

3 结论

(1)分析了城市轨道交通突发事件的实际数据,采用改进的Im-F-score+XGB算法对突发事件风险特征进行筛选,通过对比分析,计算出各风险特征的重要度,得到日路网客运量、实际开行列车数、列车兑现率、延误时长、机场线断面满载率、4-大兴线断面满载率以及16号线断面满载率这7个指标为与路网突发事件风险等级判别关系显著的重要风险特征。运营管理人员可以通过重点关注这几项特征的变化,有针对性地指导风险防控工作。

(2)将改进的多时间窗循环扫描方法和加权级联残差深度森林模型应用到对风险特征与突发事件风险等级映射关系的剖析中。通过建立Im-F-GCF风险等级判别模型,实现了对城市轨道交通突发事件风险等级的判别。与传统的GCF、RandomForest、HGBDT、LightGBM模型进行对比分析,显示出模型在判别效果方面的优势。将最新的风险特征数据输入模型,运营管理人员能够根据判别出的风险等级提前做好应急准备。

(3)后续可针对特定类型的突发事件进行风险等级的判别与预测,以提升不同场景风险等级评价的效果。

参考文献:

- [1] Wang J, Yan W, Xu H, et al. Investigation of the probability of a safe evacuation to succeed in subway fire emergencies based on Bayesian theory[J]. KSCE Journal of Civil Engineering, 2018, 22(3): 877-886.
- [2] Yan H, Gao C, Elzarka H, et al. Risk assessment for construction of urban rail transit projects[J]. Safety Science, 2019, 118: 583-594.
- [3] Singh R, Hörcher D, Graham D J, et al. Decomposing journey times on urban metro systems via semiparametric mixed methods[J]. Transportation Research Part C: Emerging Technologies, 2020, 114: 140-163.
- [4] 汪益敏, 罗跃, 于恒, 等. 人员密集型地铁车站安全风险评价方法[J]. 交通运输工程学报, 2020, 20(5): 198-207.
Wang Yi-min, Luo Yue, Yu Heng, et al. Evaluation method of security risk on crowded metro station [J]. Journal of Traffic and Transportation Engineering, 2020, 20(5): 198-207.
- [5] 李炜, 周丙相, 蒋栋年, 等. 基于多状态时间序列预测学习的电源车故障预测方法[J]. 吉林大学学报:工学版, 2020, 50(4): 1532-1544.
Li Wei, Zhou Bing-xiang, Jiang Dong-nian, et al. Fault prediction of power supply vehicle based on multi-state time series prediction learning[J]. Journal of Jilin University (Engineering and Technology Edition), 2020, 50(4): 1532-1544.
- [6] 郑宣传, 魏运, 秦勇, 等. 一种改进K-means模型的城市轨道交通突发事件分级方法[J]. 交通运输系统工程与信息, 2019, 19(3): 134-140.
Zheng Xuan-chuan, Wei Yun, Qin Yong, et al. Classification method of urban rail transit emergencies based on improved K-means algorithm[J]. Journal of Transportation Systems Engineering and Information Technology, 2019, 19(3): 134-140.
- [7] Mohanty S, Pozdnukhov A, Cassidy M. Region-wide congestion prediction and control using deep learning[J]. Transportation Research Part C: Emerging Technologies, 2020, 116: 1-21.
- [8] Yu B, Lee Y, Sohn K. Forecasting road traffic speeds by considering area-wide spatio-temporal dependencies based on a graph convolutional neural network (GCN) [J]. Transportation Research Part C: Emerging Technologies, 2020, 114: 189-204.
- [9] He D, Zou Z, Chen Y, et al. Obstacle detection of rail transit based on deep learning[J]. Measurement, 2021, 176: 109241.

- [10] Paltrinieri N, Comfort L, Reniers G. Learning about risk: machine learning for risk assessment[J]. *Safety Science*, 2019, 118: 475-486.
- [11] Zhou Z H, Feng J. Deep forest: towards an alternative to deep neural networks[C]//IJCAI, Melbourne, Australia, 2017: 3553-3559.
- [12] Liu X, Tian Y, Lei X, et al. Deep forest based intelligent fault diagnosis of hydraulic turbine[J]. *Journal of Mechanical Science and Technology*, 2019, 33(5): 2049-2058.
- [13] Zhang Y, Xu T, Chen C, et al. A hierarchical method based on improved deep forest and case-based reasoning for railway turnout fault diagnosis[J]. *Engineering Failure Analysis*, 2021, 127: 105446.
- [14] 姜万录, 李满, 张培尧, 等. 基于全矢增强深度森林的旋转设备智能故障诊断方法[J]. *中国机械工程*, 2022, 33(11): 1324-1335.
- Jiang Wan-lu, Li Man, Zhang Pei-yao, et al. Intelligent fault diagnosis method for rotating equipment derived from full vector enhanced deep forest[J]. *China Mechanical Engineering*, 2022, 33(11): 1324-1335.
- [15] 邵怡韦, 陈嘉宇, 林翠颖, 等. 小训练样本下齿轮箱故障诊断:一种基于改进深度森林的方法[J]. *航空学报*, 2021, 42(增刊1): 25-29.
- Shao Yi-wei, Chen Jia-yu, Lin Cui-ying, et al. Gearbox fault diagnosis under small training samples: An improved deep forest based method[J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(Sup. 1): 25-29.
- [16] 李志慧, 孙雅倩, 陶鹏飞, 等. 交通事故后的交通运行风险状态等级预测方法[J]. *吉林大学学报:工学版*, 2022, 52(1): 127-135.
- Li Zhi-hui, Sun Ya-qian, Tao Peng-fei, et al. Prediction method of traffic operation risk level after traffic accident[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2022, 52(1): 127-135.