

考虑易用性和可解释性的自组织映射-即时学习风险预测框架

马潇驰^{1,2,3,4}, 陆建^{1,2,3}, 霍宗鑫^{1,2,3}, 夏萧菡^{1,2,3}

(1. 东南大学江苏省城市智能交通重点实验室, 211189, 南京; 2. 东南大学现代城市交通技术江苏高校协同创新中心, 211189, 南京; 3. 东南大学交通学院, 211189, 南京; 4. 南洋理工大学土木与环境工程学院, 639798, 新加坡)

摘要: 为提高风险预测系统的易用性和可解释性,提出基于自组织映射网络(SOM)改进的即时学习(JITL)风险预测框架。首先,应用 SOM 对数据样本进行聚类,并对聚类特征进行解释。进而,通过基于聚类结果的样本选择算法构建待测数据的相似样本集,在线上调用作为基学习器的支持向量机(SVM)进行建模并输出风险预测结果。最后,采用一个交通事故数据集对风险模型的性能进行测试,检验其精度、易用性和可解释性。结果表明:采用 SOM-JITL 策略的 SVM 模型,受试者工作状况曲线面积指标达到 0.720,相比不使用该策略的传统 SVM 模型提高 17.5%,精度较高;SOM-JITL 模型构建所需参数调节工作少,具有较好的易用性;此外,SOM 聚类结果准确识别出处于交通拥堵等高风险场景,与现实场景一致,具有可解释性。综上,SOM-JITL 策略能有效提高基学习器的性能,达到精度、可解释性和易用性的平衡,有助于以低成本大规模推广风险预测系统。

关键词: 机器学习;风险预测;易用性;可解释性;即时学习;自组织映射

中图分类号: U491.3 **文献标志码:** A

DOI: 10.7652/xjtuxb202405020 **文章编号:** 0253-987X(2024)05-0212-09

A Risk Prediction Framework Based on Self-Organizing Mapping and Just-in-Time-Learning Considering Usability and Interpretability

MA Xiaochi^{1,2,3,4}, LU Jian^{1,2,3}, HUO Zongxin^{1,2,3}, XIA Xiaohan^{1,2,3}

(1. Jiangsu Key Laboratory of Urban ITS, Southeast University, Nanjing 211189, China; 2. Jiangsu Province Collaborative Innovation Center of Modern Urban Traffic Technologies, Southeast University, Nanjing 211189, China; 3. School of Transportation, Southeast University, Nanjing 211189, China; 4. School of Civil and Environment Engineering, Nanyang Technological University, Singapore 639798, Singapore)

Abstract: To enhance the usability and interpretability of risk prediction system, a traffic risk prediction framework based on just-in-time learning (JITL) improved via self-organizing mapping (SOM) is proposed. Firstly, SOM is applied for clustering the data samples and interpreting the clustering features. Then, a sample selection algorithm based on clustering results is used to construct a similar sample set for the data to be tested, and the support vector machine (SVM), which is the base learner, is invoked online to model and output the risk prediction results. Lastly, the model performance is tested using a traffic flow-crash dataset to evaluate interpretability and accuracy. The results show that the area under receiver operating characteristic curve of the SVM model using the

SOM-JITL strategy reaches 0.720, which is 17.5% higher than that of the traditional SVM model without the strategy. The SOM-JITL requires less parameter adjustment, and has better usability. In addition, the clustering results of the SOM-JITL accurately identify high-risk scenarios, such as traffic congestion, which is consistent with realistic scenarios and has interpretability. In summary, the SOM-JITL can effectively enhance the performance of the base learner, and endow the model with balance among accuracy, interpretability and usability, facilitating the cost-effective and large-scale deployment of risk prediction systems.

Keywords: machine learning; risk prediction; usability; interpretability; just-in-time learning; self-organized map

风险预测深入生产生活的各方面,为了防止事故发生,许多领域都已建立了特定的风险预测模型,为相关事业的安全稳定做出了巨大贡献。在医学领域,已形成多项疾病的风险预测应用^[1];在金融领域,大量针对企业破产和个人信用的风险评估指导着银行制定合理的投资方案^[2];在交通领域,预测系统实时监测着风险因子的变化以规避交通事故的发生^[3]。为了获得更可靠的风险预测系统,在过去的研究中,以计量经济学模型为基础的各类风险预测模型被广泛应用,包括 Logistics 模型^[4]、贝叶斯方法^[5]等,此类模型针对风险致因的相关性进行研究,易于理解,但普遍存在识别精度相对较低的问题。随着智能算法和数据采集技术的快速发展,已有多个领域开始采集大量系统正常运行和处于故障时的数据,并使用机器学习对行业内出现的事故风险进行预测和评估^[6]。以深度学习为代表的复杂机器学习模型随后也被引入事故风险的研究中^[7],进一步提高了风险预测的精度。

风险预测模型的可解释性是能否执行管理决策的依据。深度学习框架作为黑箱模型带来的低可解释性容易造成法律上的责任归属不明确^[8],从而限制风险预测系统的应用。已有学者对可解释机器学习展开研究^[9],提出利用特征重要度或代理模型对变量的影响进行分析,并将解释结果和现实场景进行对比,以此检验模型的可解释性^[10]。另一方面,深度学习模型的建立需要复杂的训练和参数调试知识。对于不同数据集,往往需要专家重新进行调参训练才能投入使用^[11],所训练的模型无法大规模推广,成本耗费高昂,易用性不强。因此,亟需提出新的风险预测模型达到精度、解释能力和易用性三者间的平衡,理想模型应该同时具有场景识别和短时风险预测的功能^[12],且不需要复杂的算法参数调节知识就能完成模型建立并投入使用。

基于以上目标,本文提出基于自组织映射聚类

(SOM)改进的即时学习策略(JITL),以支持向量机(SVM)作为基学习器,结合 SOM-JITL 构建风险预测框架,旨在完成风险场景识别和短时风险预测^[13],同时赋予模型高精度、可解释性和易用性。本研究的贡献主要在于:采用 SOM 聚类完成场景识别,实现了模型可解释性的提升;利用即时学习策略提高了模型易用性和基学习器精度;采用交通事故数据集对建立的 SOM-JITL-SVM 模型进行测试,通过对比各个基线方法的性能指标,验证 SOM-JITL 策略为风险预测模型带来的有益提升。

1 模型算法

1.1 改进的自组织映射-即时学习算法

JITL 的基本思想是将传统“离线建模、线上工作”的模式转变为“线上同时建模和工作”。传统模型是在系统训练完成后提供用户使用,JITL 是在线上同时建立模型和实现用户需求,两者的工作流程对比如图 1 所示。JITL 首先将所有已有样本存储在历史样本数据库中,当用户提交测试需求时,通过预设规则选择待测数据小邻域范围内的样本,建立相似样本子集,再使用相似样本子集在线上建模和结果输出。在输出结果后,当前模型将被立刻舍弃,为一次性使用的模型。与传统建模策略相比,JITL 可以有效地处理样本差异性较大的分类问题,提升传统方法难以解决的不平衡分类问题的准确度^[14]。

在采用 JITL 策略并应用基学习器进行建模前,需根据数据之间的相似度在历史样本数据库中挑选出相似样本子集。相似度的计算方法可以使用欧氏距离、汉明距离、曼哈顿距离等^[15],多数文献使用基于欧氏距离的 K 近邻方法。但是,使用 K 近邻方法需要提前预设待选样本数量,过少的样本数量会使样本子集的信息缺失,过多的数量会引入噪声,都会影响建模质量。因此,本文提出基于 SOM 聚类结果的改进 JITL 样本子集构建算法。

SOM 是一种用于聚类和特征提取的神经网络

无监督学习算法。对于具有 K 个样本的向量组 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_K]$, SOM 将其映射到具有指定神经元(簇)拓扑结构的二维空间中,为探索最佳的神经元数量,在建模时将使用多组网络结构对比其性能。

SOM 的训练过程采用胜者通吃的激活机制,每一次比较输入向量和神经元向量(簇心)的欧氏距离,与输入向量相似性最大的神经元获胜,并对周围邻域的神经元权值进行更新。权值 w 的更新公式为

$$w \leftarrow w + \eta h(d)(x - w) \quad (1)$$

式中: η 是学习率; $h(\cdot)$ 是衰减函数,在实际应用中常使用高斯函数; d 是激活神经元和其他神经元之间的距离,一般为在网络结构中的坐标距离。




图 1 JITL 策略与传统建模工作流程对比

Fig.1 Comparison of JITL strategy and traditional modeling workflow

在完成历史样本数据的 SOM 聚类后,当输入待测样本时,判断待测样本所属的 SOM 簇,再根据该 SOM 簇的相似簇心构造相似簇集合,进一步根据子簇心的相似簇心扩大相似簇集合,以此循环。将所属相似簇集合的历史样本作为相似样本子集,相似簇心的判别条件可使用簇心距离集合的均值或 25% 分位值,具体算法如下。

算法 1: 基于 SOM 聚类结果的 JITL 相似样本子集构造

输入: SOM 簇编号集合 $I = \{1, 2, \dots, N\}$, SOM 簇心向量 $\mathbf{W} = \{w_i, i = I\}$, SOM 簇心距离矩阵 $\mathbf{D} = \{d_{ij}, i = I, j = I\}$, SOM 簇心邻接矩阵 $\mathbf{A} = \{a_{ij}, i = I, j = I\}$, 历史样本集 $H = \{x_q, q = 1, 2, \dots\}$, 待测数据 x_p

输出: 待测数据 x_p 的相似样本子集 S

```

1  初始化
2   $t \leftarrow \arg\min_i (x_p - w_i)$ 
3   $Q \leftarrow (\max D - \min D)0.25 + \min D$ 
4   $C \leftarrow \{t\}$ 
5   $k \leftarrow 1$ 
6   $l \leftarrow 1$ 
7  搜索相似簇
8  Do
9       $i \leftarrow C_k$ 
10     Do
11         if  $a_{ij} = 1 \ \& \ d_{ij} \leq Q \ \& \ j \notin C$ 
12              $C \leftarrow \{C, j\}$ 
13          $l \leftarrow l + 1$ 
14     end
15     Until 遍历  $i$  所有邻接点  $j$ 
16      $k \leftarrow k + 1$ 
17     Until  $k > l$ 
18      $S \leftarrow \{H_C\}$ 

```

1.2 基学习器: 支持向量机

SVM 是一个经典而高效的分类器,其通过搜索支持向量并构造它们的线性或非线性组合来确定分类超平面^[16]。采用 SVM 作为 SOM-JITL 策略的基学习器,优势在于 SVM 超参数较少,便于调校投入使用。在后续建模测试中,仅使用 SVM 建模的推荐参数。一个典型的非线性 SVM 可以被定义为

$$F(x) = \text{sgn} \left(\sum a_i^* y_i K(\mathbf{x}, \mathbf{x}_i) + b^* \right) \quad (2)$$

式中: a_i^* 是优化后拉格朗日乘子; y_i 是支持向量的类别; $K(\mathbf{x}, \mathbf{x}_i)$ 为核函数; $\mathbf{x}_i$ 为支持向量; b^* 为截距。

1.3 基线: 极端梯度提升

XGBoost 在梯度提升树的基础上进行了大量改进,被认为在分类和回归问题上都具有极高的性能,在交通事故风险预测中也有较多应用^[17]。XGBoost 代表复杂机器学习在本文中成为基线,在建模测试中调用 python 的 XGBoost 库实现该模型,其超参数较多,参数调试过程较为复杂,通常需要反复调试以避免过拟合的情况发生。

1.4 超参数选取

采用贪心算法对 XGBoost 超参数进行调节,即在参数的推荐值范围内逐个尝试,当一个参数调至最优时,再进行下一个参数的优化,简要的算法流程如下所示。

算法 2:基于贪心算法的机器学习超参数优化

输入:待优化超参数数组 $A = \{a_1, a_2, \cdots, a_n\}$, 训练数据集 $T = \{(\mathbf{x}_j, y_j)\}$, 待优化超参数取值上下限 $U = \{u_1, u_2, \cdots, u_n\}, D = \{d_1, d_2, \cdots, d_n\}$, 使用超参数数组 A 进行训练的学习器 $y = f_A(X)$

输出:优化的超参数数组 $A^* = \{a_1^*, a_2^*, \cdots, a_n^*\}$

```
1  初始化
2   $i \leftarrow 1, A \leftarrow \{a_1, a_2, \cdots, a_n\}$ 
3  Do
4       $a_i^* \leftarrow \operatorname{argmin}_{a_i} (\sum_j \|f_A(\mathbf{x}_j) - y_i\|)$  subject
        to  $d_i \leq a_i^* \leq u_i$ 
5       $i \leftarrow i + 1$ 
6  Until  $i > n$ 
7   $A^* \leftarrow A$ 
```

本实验中选用的 SVM 默认参数和优化后的 XGBoost 主要参数值可直接参考表 1。

表 1 本文实验选用的学习器参数

Table 1 Learners’ parameters selected for this experiment

方法	参数
SVM	核函数:径向基
	核尺度参数:1
	学习参数:0.01
	离群值预设比例:0
XGBoost	决策树数量:190
	学习率:0.08
	最大深度:6
	列采样比例:0.7
	L_1 正则化权重:0.9
	L_2 正则化权重:0.2
	叶节点分支损失最小值:0.35

表 2 交通事故数据集结构及变量描述

Table 2 Traffic crash data set structure and variable descriptions

参数	变量含义	最小值	最大值	均值
$f_1/\text{辆}$	观测点上游传感器采集的前 5~10 min 交通量	19.00	161.00	102.28
$f_2/\text{辆}$	观测点下游传感器采集的前 5~10 min 交通量	22.00	183.00	118.74
$O_1/\%$	观测点上游传感器采集的前 5~10 min 车道占有率	1.75	71.00	33.42
$O_2/\%$	观测点下游传感器采集的前 5~10 min 车道占有率	2.33	69.60	36.49
$v_1/(\text{km} \cdot \text{h}^{-1})$	观测点上游传感器采集的前 5~10 min 平均车速	6.80	76.64	39.97
$v_2/(\text{km} \cdot \text{h}^{-1})$	观测点下游传感器采集的前 5~10 min 平均车速	9.70	84.10	43.17
c	观测点路段是否发生事故,为二分类 0-1 变量	0	1.00	0.25

2 测试数据

2.1 数据集构造

本研究旨在通过和现实场景进行比对来验证可解释性,因此选择基于实际工程背景的交通事故数据集进行测试。原始数据为浙江杭州上塘快速路 2015 年 3 个月间的交通流和事故记录。交通流记录包括传感器每 5 min 内记录一次该时段内的断面交通量、平均车速和车道占有率。事故记录由公安交警部门提供,共包括 123 起事故。为对事故风险进行提前预警,对每一起事故,将事故点所在路段上下游传感器采集的前 5~10 min 内的交通量、占有率和车速数据作为特征变量,共 6 个自变量。

交通事故相对于正常行驶状态是稀有事件,使用全样本数据集容易导致数据不平衡问题^[18]。目前在风险预测研究中,普遍采用病例对照法来构造数据集^[19],通过对每一个病例(事故)选取一定数量的正常样本作为对照组,能在平衡数据样本的同时探索病例(事故)的影响因素。因此,本研究参考病例对照法,对每条事故数据,随机选择了相同观测路段、相同时间、不同日期的 3 条非事故数据进行匹配,并作相应的特征变量计算,最终数据集共计 492 条数据,数据结构及变量描述见表 2。

在使用表 2 交通事故数据集进行性能测试时,对传统的建模方法,依旧划分训练集和测试集,两个集合的数据比例为 75%和 25%,且两个集合中事故数据和非事故数据的比例仍控制在约 1:3。考虑到 JITL 策略独特的“用后即弃”模型使用方法,为保持模型评价时精度指标的一致性,所有应用 JITL 策略的方法使用 75%的数据作为历史样本数据,25%的数据作为测试数据。

2.2 精度评价指标

杭州事故测试数据集为典型的二分类问题数据集,当模型输出为连续值时,使用受试者工作状况(ROC)曲线下的面积 A_{uc} 来表征模型的综合精度。ROC 曲线为在不同分类阈值 t 下以假阳性率 R_{fp} 为横坐标、真阳性率 R_{tp} 为纵坐标描画的曲线。假阳性率代表有多少正常状况被误检为险情,真阳性率代表有多少险情被正确识别,其分类混淆矩阵见表 3,计算方法如下

$$R_{fp} = \frac{n_{FP}}{n_{FP} + n_{TN}} \tag{3}$$

$$R_{tp} = \frac{n_{TP}}{n_{TP} + n_{FN}} \tag{4}$$

式中: n_{TP} 、 n_{FP} 为真阳性、假阳性案例数量; n_{TN} 、 n_{FN} 为真阴性、假阴性案例数量。

显然一个高精度的模型应当具有低假阳性率和高真阳性率,此时 ROC 曲线会更饱满,相应 A_{uc} 指标更高。

表 3 分类问题的混淆矩阵

Table 3 Confusion matrix for classification problems

预测状况	案例数量	
	实际为发生 ($c=1$)	实际未发生 ($c=0$)
预测为发生($c^*=1$)	真阳性 n_{TP}	假阳性 n_{FP}
预测未发生($c^*=0$)	假阴性 n_{FN}	真阴性 n_{TN}

注: c 、 c^* 分别为观测点路段事故的实际值、预测值。

通过调整不同的分类阈值,可以在容许更高假阳性率的前提下提高模型的真阳性率,采用最大约登指数 y_d 作为最终分类阈值,即 ROC 曲线上的纵坐标与横坐标之差最大时对应的分类阈值,并采用 F1 分数指标 F_{score} 综合评价此时的模型性能,两者计算公式如下

表 4 不同方法构建的预测模型性能对比

Table 4 Comparison of the prediction models' performance based on different methods

方法	精度性能				参数选择	耗时/ms
	A_{uc}	R_{tp}	R_{fp}	F_{score}		
SVM	0.613	0.520	0.375	0.634	默认参数	0.065
JITL-SVM	0.648	0.720	0.371	0.788	20%样本子集	0.308
XGBoost	0.702	0.839	0.444	0.823	贪心算法优化超参数	0.197
SOM-JITL-SVM	0.720	0.774	0.370	0.853	4×2 SOM 网络	0.543

注:表中加粗数据为最优值。

3.1 精度性能讨论

在 SOM-JITL-SVM 模型中,对多组 SOM 网络结构进行测试,从 2×1 结构遍历至 7×7,共比较 27 个网络结构的模型精度,每种结构进行 30 次实验,以多次实验 A_{uc} 指标的均值为中心、标准差为长度

$$y_d = \operatorname{argmax}_t [R_{tp}(t) - R_{fp}(t)] \tag{5}$$

$$F_{score} = \frac{2n_{TP}}{2n_{TP} + n_{FN} + n_{FP}} \tag{6}$$

3 结果和讨论

分别使用 SVM、XGBoost、JITL-SVM 和 SOM-JITL-SVM 模型在事故数据集上对风险进行预测,各模型选择参数后的性能测试结果如表 4 所示。从模型的 A_{uc} 和 F_{score} 指标项可以发现,直接使用 SVM 模型进行风险预测效果不佳;在应用了 JITL 策略后,性能得到提升, A_{uc} 指标达到 0.648;当联合应用 SOM-JITL 策略时, A_{uc} 指标为 0.720,较 SVM 提升 17.5%,较 JITL-SVM 提升 11.1%,其 A_{uc} 和 F_{score} 指标在各个模型中均表现最好,此时模型能正确识别 77.4%的险情,误报率为 37%。

在易用性方面,SOM-JITL-SVM 模型仅需确定使用的聚类网络结构,XGBoost 则需要专家知识确认超参数优化的上、下限,并使用贪心算法优化超参数值。结合两者的精度性能,SOM-JITL-SVM 的调参过程更简单,精度能达到甚至超过 XGBoost 的水平,因此 SOM-JITL-SVM 具有更好的易用性。

此外,根据每一次待测数据从输入到风险结果输出的耗时,计算了各模型的平均预测时间。由表 4 耗时项可知,由于 JITL 策略是线上建模并输出结果,对比传统模型增加了训练模型所需的时间,但平均每一次预测用时都能控制在 0.543 ms 左右,考虑硬件性能和冗余,SOM-JITL 的计算耗时能满足短时风险预测的时效性需要。

下面,将具体论述 SOM-JITL 的精度性能、易用性和可解释性。

绘制误差棒,结果如图 2 所示。

由图 2 易发现,当网络结构为 4×2 时,模型 A_{uc} 的均值最高,达到 0.720,标准误差为 0.015,在可接受范围内。因此,选择 4×2 网络结构、 A_{uc} 为 0.720 的 SOM-JITL-SVM 模型作为代表。




图 2 不同网络结构 SOM-JITL-SVM 精度性能

Fig. 2 SOM-JITL-SVM accuracy performance for different network structures

图 2 中 A_{uc} 均值随网络结构的变化而波动。性能稳定、 A_{uc} 均值较高且标准差较小的网络结构有 3×1 、 3×2 、 3×3 、 4×2 、 5×2 、 7×1 , 其神经元数量均在 $3 \sim 10$ 之间, 每个神经元命中的样本数量期望为 $30 \sim 100$, 考虑到 SOM 相似样本集选取算法会使多个簇聚为一类, 实际每个类别的样本会比期望值更多。

在 JITL-SVM 模型中采用了 K 近邻相似样本选择法, 即选取相似样本的比例为原始数据集中欧氏距离最小的前 10% 、 20% 和 30% 个样本, 构造相似样本子集训练。最终实验结果表明, 选择前 20% 的相似样本所获得的效果最佳, 与 SOM 聚类的样本数量结果类似。即在 JITL 构建相似样本子集时, 控制相似样本集大小在 $30 \sim 140$ 之间可以获得最佳性能^[20], 可以根据不同的基学习器微调样本集大小, 但低于或超过这个范围的性能都会存在较大波动。故 SOM 网络中的神经元数量 N 应大致满足与历史样本数 M 的如下关系

$$30 < \frac{M}{N} < 140 \tag{7}$$

综上, 在精度要求上, SOM-JITL 策略实现了基学习器性能的较大提升, 所形成的风险预测模型达到和复杂机器学习一致的水平。

3.2 易用性讨论

在建模过程中, SOM-JITL-SVM 使用基学习器的默认参数, 仅在 SOM 的网络结构配置上进行了一次参数调节, 实际应用时可以按式(7)推算。

在采用 XGBoost 算法进行数据集测试时, 遵循算法 2, 采用贪心算法进行求解最优超参数。使用初始参数时, 训练集 A_{uc} 指标接近 1, 测试集 A_{uc} 仅为 0.6, 形成巨大的训练测试集指标差, 显然 XGBoost 在训练集上过拟合。进行超参数调节后, 模型 A_{uc} 指标的训练测试集指标差为 0.139, 不再过拟合。


如更换数据集, 则需要再次进行上述过程。

结合表 4 的模型精度对比结果, SOM-JITL 策略极大地简化了机器学习模型的参数调试过程, 使利用较少的调参知识完成风险预测建模成为可能。在考虑模型易用性并有较高精度需求时, SOM-JITL 策略是一种行而有效的方法。

3.3 可解释性讨论

在验证了 SOM-JITL 的精度性能和易用性后, 需进一步对其在机器学习范畴内的可解释性进行讨论, 以确定 SOM-JITL 的普适和易用性是从数据中自发学习风险特征得到, 而不是通过一个复杂的过拟合过程产生。

以 3.1 中获得的 4×2 网络结构的 SOM-JITL-SVM 模型为例, 讨论模型可解释性。该模型中 SOM 簇心邻接权重如图 3 所示, 权重颜色越深代表两个簇心的距离越大, 算法将距离较近的 1、2、6 号簇心连接为一个类(1-2-6), 其余簇心单独成一个类。按每一类别内的事数数和样本数比值计算事故率, 按事故率升序排列得到从风险等级 I 到 VI 的 6 类交通运行场景。表 5 描述了 SOM 在杭州上塘快速路上识别的 6 类交通运行场景, 以及每个场景的交通流和事故率特征。



1~8 为簇心; 颜色越深代表两个簇心距离越大。

图 3 SOM 簇心邻接权重距离热力图

Fig. 3 Weight distance between neighbor SOM cluster centers

表 5 SOM 识别的 6 类交通运行场景特征

Table 5 6 types of traffic operation scene features identified by SOM

类别	簇心	交通量/辆		车道占有率/%		平均车速/(km·h ⁻¹)		样本数	事故数	事故率/%	场景
		上游	下游	上游	下游	上游	下游				
I	4	52.4	74.9	18.3	16.3	50.1	62.6	24	3	12.5	正常
II	3	89.7	128.7	18.9	29.1	56.9	54.2	45	8	17.8	正常
III	7	107.7	93.5	27.0	19.8	45.0	54.4	31	6	19.4	正常
IV	5	131.9	105.9	40.1	37.4	33.6	33.7	46	11	23.9	正常
V	1-2-6	109.2	146.5	39.8	40.5	35.6	44.9	154	45	29.2	高风险
VI	8	93.1	91.4	35.2	50.5	32.9	21.3	62	23	37.1	高风险

由表 5 可知,第 V 类和第 VI 类场景的事故率最高,事故数超过其他 4 类总和的两倍,需重点分析。第 V 类交通场景的特征是上下游交通量差距较大,且交通量和运行速度都随着车辆的前进逐步升高,但车道占有率并没有改变。检查原始数据的采集编号可定位此类场景是典型的车辆合流区^[21-22],在合流过程中交通运行复杂,易发生事故。虽然第 I 类场景也存在类似的交通量和速度增大、车道占有率不变的特征,但其速度更接近运行限速^[23],是交通量总体较小、路况良好的自由流状态。第 VI 类场景的上下游车道占有率极大提高而速度显著下降,该情况发生在拥堵的分流区,车道数减少但交通量未明显减少^[24],会频繁发生超车、别车、加塞等不良驾

驶行为,导致事故高发。由第 V 类和第 VI 类的高风险特征,结合第 IV 类场景的车道占有率显著高于第 I、第 II、第 III 类且第 IV 类事故率也较高的现象可以得出,高车道占有率的交通运行状况是事故多发场景^[25],应重点排查在交织区路段高车道占有率情况下的风险隐患,与现实场景一致。

综上,不同于传统机器学习模型的事后解释,SOM-JITL 将变量解释工作迁移到建模之前,最大限度地保留了数据信息,易于理解,拥有良好的可解释性,同时增强了 SOM-JITL 模型的易用性和实用性。如图 4 所示,SOM 的聚类结果可作为风险评估的初步结论、JITL-SVM 的预测值可作为精细化评估结论,形成两阶段、多层次的风险评估流程。




图 4 基于 SOM-JITL 策略的场景识别及风险评估流程

Fig. 4 Scenario identification and short-time risk assessment process of SOM-JITL

4 结 论

考虑精度、可解释性和易用性的平衡,本文提出了基于自组织映射改进即时学习策略(SOM-JITL)

的风险预测框架,采用交通事故数据集作为实例分析,主要结论如下。

(1)在交通事故数据集的测试中,应用了 SOM-JITL 策略的 SVM 基学习器性能得到大幅提高。

与不使用该策略的传统 SVM 模型相比, A_{uc} 指标提高 17.5% 达到 0.720, 能够正确识别 77% 的高风险警情, 达到和复杂机器学习 XGBoost 模型一致的水平, 具有较高的精度; 单次运行时间为 0.543 ms, 亦满足短时预测时效性的要求。

(2) SOM-JITL 策略的参数调试简单, 易于使用, 作为其基学习器的 SVM 模型仅使用默认推荐参数, 性能即达到和进行了较复杂调参的 XGBoost 模型一致的水平。SOM-JITL 策略的参数调试工作主要是选择 SOM 网络结构, 本文提出了神经元数量估算公式以简化该过程, 当每个神经元的期望样本数量在 30~150 时, SOM-JITL 策略能达到较高的性能, 以此实现了 SOM-JITL 策略的良好易用性。

(3) SOM-JITL 策略在建模前采用 SOM 对数据进行聚类分析, 完成风险场景识别, 在事故数据集中, SOM 聚类结果表明, 高车道占有率场景下的事故率显著提高, 拥堵状态下的合流、分流区更容易发生交通事故, 与实际相符。这表明 SOM-JITL 策略具有良好可解释性, 能够快速学习数据中的风险特征。

(4) SOM-JITL 策略结合不同的基学习器实现了风险预测框架的高精度、可解释性和易用性的平衡, 适用于各领域内的风险预测问题。但是, 本研究仅对风险的预测预警进行了讨论, 尚未考虑发现风险后的主动防控措施, 这是未来研究中进一步提高 SOM-JITL 风险预测框架应用价值的研究方向。

参考文献:

- [1] NADARAJAH R, YOUNSI T, ROMER E, et al. Prediction models for heart failure in the community: a systematic review and meta-analysis [J]. *European Journal of Heart Failure*, 2023, 25(10): 1724-1738.
- [2] ZELENKOV Y, FEDOROVA E, CHEKRIZOV D. Two-step classification method based on genetic algorithm for bankruptcy forecasting [J]. *Expert Systems with Applications*, 2017, 88: 393-401.
- [3] YU Le, DU Bowen, HU Xiao, et al. Deep spatio-temporal graph convolutional network for traffic accident prediction [J]. *Neurocomputing*, 2021, 423: 135-147.
- [4] HUO Xiaoyan, LENG Junqiang, LUO Lijun, et al. A mixed logit model with mean-variance heterogeneity to investigate factors of crash occurrence [J]. *International Journal of Injury Control and Safety Promotion*, 2021, 28(3): 301-308.
- [5] KAMEL A, SAYED T, FU Chuanyun. Real-time safety analysis using autonomous vehicle data: a Bayesian hierarchical extreme value model [J]. *Transportmetrica: B Transport Dynamics*, 2023, 11(1): 826-846.
- [6] CHEN T K, LIAO H H, CHEN Gengdao, et al. Bankruptcy prediction using machine learning models with the text-based communicative value of annual reports [J]. *Expert Systems with Applications*, 2023, 233: 120714.
- [7] BRITO M P, STEVENSON M, BRAVO C. Subjective machines: Probabilistic risk assessment based on deep learning of soft information [J]. *Risk Analysis*, 2023, 43(3): 516-529.
- [8] KRAFFT T D, ZWEIG K A, KÖNIG P D. How to regulate algorithmic decision-making: a framework of regulatory requirements for different applications [J]. *Regulation & Governance*, 2022, 16(1): 119-136.
- [9] KHATTAK A, CHAN P W, CHEN Feng, et al. Interpretable ensemble imbalance learning strategies for the risk assessment of severe-low-level wind shear based on LiDAR and PIREPs [J/OL]. *Risk Analysis*, 2023[2023-07-12]. <https://doi.org/10.1111/risa.14215>.
- [10] BOSTROM A, DEMUTH J L, WIRZ C D, et al. Trust and trustworthy artificial intelligence: a research agenda for AI in the environmental sciences [J/OL]. *Risk Analysis*, 2023[2023-07-12]. <https://doi.org/10.1111/risa.14245>.
- [11] MANNERING F, BHAT C R, SHANKAR V, et al. Big data, traditional data and the tradeoffs between prediction and causality in highway-safety analysis [J]. *Analytic Methods in Accident Research*, 2020, 25: 100113.
- [12] GUTIERREZ-OSORIO C, PEDRAZA C. Modern data sources and techniques for analysis and forecast of road accidents: a review [J]. *Journal of Traffic and Transportation Engineering(English Edition)*, 2020, 7(4): 432-446.
- [13] 杨文臣, 周燕宁, 田毕江, 等. 基于聚类分析和 SVM 的二级公路交通事故严重度预测 [J]. *中国安全科学学报*, 2022, 32(5): 163-169.
- [14] YANG Wenchen, ZHOU Yanning, TIAN Bijiang, et al. Traffic accident severity prediction for secondary highways based on cluster analysis and SVM model [J]. *China Safety Science Journal*, 2022, 32(5): 163-169.
- [14] QI Long, LIU Hui, XIONG Qian, et al. Just-in-time-

- learning based prediction model of BOF endpoint carbon content and temperature via vMF mixture model and weighted extreme learning machine [J]. *Computers & Chemical Engineering*, 2021, 154: 107488.
- [15] ZHAO Dan, PAN Tianhong, SHENG Biqu. Just-in-time learning algorithm using the improved similarity index [C]//2016 35th Chinese Control Conference (CCC). Piscataway, NJ, USA: IEEE, 2016: 9065-9068.
- [16] WANG Ling, ABDEL-ATY M, LEE J, et al. Analysis of real-time crash risk for expressway ramps using traffic, geometric, trip generation, and socio-demographic predictors [J]. *Accident Analysis & Prevention*, 2019, 122: 378-384.
- [17] PARSA A B, MOVAHEDI A, TAGHIPOUR H, et al. Toward safer highways, application of XGBoost and SHAP for real-time accident detection and feature analysis [J]. *Accident Analysis & Prevention*, 2020, 136: 105405.
- [18] PARSA A B, TAGHIPOUR H, DERRIBLE S, et al. Real-time accident detection: coping with imbalanced data [J]. *Accident Analysis & Prevention*, 2019, 129: 202-210.
- [19] LI Qianwen, YAO Handong, LI Xiaopeng. A matched case-control method to model car-following safety [J]. *Transportmetrica: A Transport Science*, 2023, 19 (3): 2055198.
- [20] ZHOU Ping, CHEN Weiqi, YI Chengming, et al. Fast just-in-time-learning recursive multi-output LSSVR for quality prediction and control of multivariable dynamic systems [J]. *Engineering Applications of Artificial Intelligence*, 2021, 100: 104168.
- [21] ZHENG Qikang, XU Chengcheng, LIU Pan, et al. Investigating the predictability of crashes on different freeway segments using the real-time crash risk models [J]. *Accident Analysis & Prevention*, 2021, 159: 106213.
- [22] SHI Qi, ABDEL-ATY M. Big data applications in real-time traffic operation and safety monitoring and improvement on urban expressways [J]. *Transportation Research: Part C Emerging Technologies*, 2015, 58, Part B: 380-394.
- [23] YU Rongjie, QUDDUS M, WANG Xuesong, et al. Impact of data aggregation approaches on the relationships between operating speed and traffic safety [J]. *Accident Analysis & Prevention*, 2018, 120: 304-310.
- [24] YANG Kui, WANG Xuesong, YU Rongjie. A Bayesian dynamic updating approach for urban expressway real-time crash risk evaluation [J]. *Transportation Research: Part C Emerging Technologies*, 2018, 96: 192-207.
- [25] 陈丰, 张婷, 黄雅迪, 等. 越江越海隧道入口段追尾事故风险预测模型研究 [J]. *交通运输系统工程与信息*, 2021, 21(6): 167-175.
- CHEN Feng, ZHANG Ting, HUANG Yadi, et al. Rear-end crash risk prediction model on entrance section of cross-river and cross-sea tunnels [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2021, 21(6): 167-175.

(编辑 杜秀杰)