

文章编号: 1005-0523(2026)02-0038-07



## 基于卷积神经网络和注意力机制的交通事故 智能预测方法

严丽平, 徐嘉悦, 吴康来, 唐仁杰, 宋凯

(华东交通大学信息与软件工程学院, 江西 南昌 330013)

**摘要:** 针对复杂环境下传统研究方法在处理高维复杂数据特征时存在局限性, 难以实现高精度鲁棒性预测的问题, 提出一种基于卷积神经网络和注意力机制的交通事故严重程度智能预测方法。通过融合卷积神经网络和注意力机制的优势, 构建了通道与多头注意力网络(channel and multi-head attention network, CMHANet)模型, 其中卷积层用于有效提取数据中的空间特征, 通道注意力机制能够对重要特征进行加权增强, 抑制不重要特征, 强化模型对关键数据点的关注。此外, 为了捕捉不同特征之间的复杂依赖关系, 还引入了多头注意力机制。最后, 在US-Accidents数据集上开展实验。实验结果表明, 以该模型为骨干的预测框架在F1分数、精确率、召回率和准确率上均有所提升。该模型在提高高维复杂数据的特征提取与关联建模效果的同时, 也为交通事故的智能预测提供了一种新的思路。

**关键词:** 卷积神经网络; 注意力机制; 交通事故; 严重程度预测

**中图分类号:** TP391.4; U491.3

**文献标志码:** A

**本文引用格式:** 严丽平, 徐嘉悦, 吴康来, 等. 基于卷积神经网络和注意力机制的交通事故智能预测方法[J]. 华东交通大学学报, 2026, 43(2): 38-44.

## Intelligent Prediction Method for Traffic Accidents Based on Convolutional Neural Network and Attention Mechanism

Yan Liping, Xu Jiayue, Wu Kanglai, Tang Renjie, Song Kai

(School of Information and Software Engineering, East China Jiaotong University, Nanchang 330013, China)

**Abstract:** In order to solve the problems that traditional research methods often have limitations in dealing with high-dimensional and complex data features in complex environments, and it is difficult to achieve high-precision and robust prediction, a traffic accidents severity intelligent prediction method based on convolutional neural network and attention mechanism is proposed. A multi-scale feature extraction model with attention fusion, which is called channel and multi-head attention network (CMHANet), is constructed to make full use of the advantages of convolution and attention mechanism. The convolution layer is used to effectively extract spatial features in the data, while the channel attention mechanism can weight and enhance important features, suppress unimportant features, and emphasize the focus on key data points. In addition, in order to capture the complex dependencies between different features, a multi-head attention mechanism is also introduced. Finally, experiments are conducted on the US-Accidents dataset. The experimental results show that the prediction framework with

收稿日期: 2023-02-28

基金项目: 国家自然科学基金项目(62362031, 62262022); 江西省自然科学基金项目(20224BAB202021)

this model as the backbone achieves improvements in F1-score, precision, recall and accuracy. While improving the effect of feature extraction and association modeling for high-dimensional and complex data, the proposed model also provides a new idea for intelligent prediction of traffic accidents.

**Key words:** convolutional neural network; attention mechanism; traffic accidents; severity prediction

**Citation format:** YAN L P, XU J Y, WU K L, et al. Intelligent prediction method for traffic accidents based on convolutional neural network and attention mechanism[J]. Journal of East China Jiaotong University, 2026, 43 (2): 38-44.

有效预测交通事故的严重程度能够为交通管理部门提供科学依据,从而优化道路设计、改善交通设施,并制定有针对性的交通管控政策。早期的交通事故预测研究主要依赖统计学模型,这类模型假设数据符合特定的概率分布,并基于该假设开展推断。然而,当假设条件不满足时,这类方法可能得出错误的结论<sup>[1-3]</sup>。此外,传统统计学模型往往难以充分捕捉交通数据中的复杂非线性关系和时空特征。随着机器学习的迅猛发展,决策树、随机森林和支持向量机等传统机器学习方法被应用于该研究领域<sup>[4-5]</sup>。然而,大数据集中存在大量不相关或冗余特征,会对预测模型的性能产生负面影响<sup>[6-8]</sup>。传统机器学习方法往往忽略了数据的时间依赖性,难以捕捉各类影响因素之间的复杂关联<sup>[9-10]</sup>。近年来,深度学习方法逐渐成为该领域的研究主流。卷积神经网络(convolutional neural network, CNN)是当前最具潜力的深度学习模型之一,已被应用于通信信号与语音片段检测、城市交通流预测、铁路轨道与信号检测、铁路轨道紧固件缺陷识别、交通拥堵预测和交通事故严重程度预测等多个场景<sup>[11-14]</sup>,其中二维卷积神经网络(2D CNN)已在文本分类<sup>[15]</sup>、通信信号处理<sup>[16]</sup>、轨道缺陷检测<sup>[17]</sup>等领域得到广泛应用。

近年来,基于注意力机制的模型在自然语言处理、目标检测、图像处理 and 机器翻译等领域得到了广泛应用<sup>[18-20]</sup>。例如,通道注意力机制在捕获复杂特征间关联方面展现出显著优势,这得益于注意力机制强大的建模能力<sup>[21]</sup>。

然而,随着交通事故数据规模的不断增加,传统预测方法在提取高维特征及捕获复杂特征关联方面存在局限性,难以满足实际预测需求。本研究提出的通道与多头注意力网络(channel and multi-head attention network, CMHANet)模型在传统CNN的基础上,引入了通道注意力机制(channel at-

tention mechanism, CAM)与多头注意力机制(multi-head attention mechanism, MHA),构建了全新的交通事故严重程度预测框架。CMHANet模型不仅能够自适应地关注输入数据中最关键的特征,还能通过CAM对特征通道进行加权处理,从而突出对预测任务最重要的信息。此外,模型采用MHA捕捉不同特征之间的长距离依赖关系,提升了模型对全局信息的理解能力。最后,将融合后的特征输入分类模块,实现交通事故严重程度的预测,分类模块包含全连接层和Softmax层,用于将融合后的特征映射为各个类别的概率,最终输出预测结果。该方法旨在解决复杂交通环境下从海量数据中高效提取、甄选关键特征的难题。

## 1 CMHANet模型整体架构

### 1.1 2D CNN

在CMHANet模型整体架构中(图1),CNN模块作为基础特征提取模块,主要负责从高维数据中提取空间特征,为后续的注意力处理提供高质量输入。为了有效捕捉数据中的局部特征和特征间的交互关系,本文采用2D CNN。二维卷积操作的核心优势在于局部感受野的设计:通过局部感受野,卷积层可以在特定区域内提取重要信息,无需依赖整个输入的全局信息,有助于模型捕捉特征之间的局部模式。在卷积操作中,卷积核的参数共享,即同一个卷积核在整个输入数据上滑动,这不仅减少了模型的参数量,提高了训练效率,还增强了模型的泛化能力,降低了过拟合风险。对于结构化数据而言,参数共享意味着模型可以在不同特征之间共享相似模式,进而提升对局部特征的捕捉能力。二维卷积操作可以表示为

$$Y(i,j) = \sum_{p=0}^{m-1} \sum_{q=0}^{n-1} X(i+p,j+q)K(p,q) \quad (1)$$

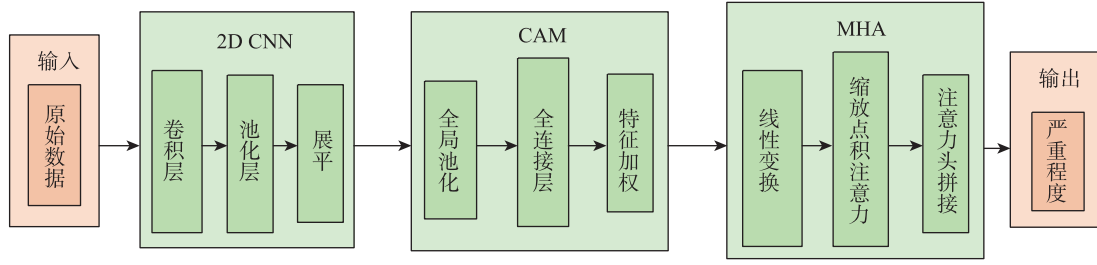


图1 CMHANet模型整体架构

Fig. 1 CMHANet model overall architecture

式中： $X(i,j)$  为输入矩阵中位置  $(i,j)$  处的元素； $K(p,q)$  为卷积核矩阵中第  $p$  行第  $q$  列元素； $Y(i,j)$  为卷积操作后的输出特征图； $m,n$  分别为表示卷积核的高与宽。

本文模型中使用多层卷积，层与层之间的关系可通过公式描述如下。第1个卷积层的输出为

$$Y_1(i,j) = \sum_{p=0}^{m_1-1} \sum_{q=0}^{n_1-1} X(i+p,j+q)K_1(p,q) \quad (2)$$

第2个卷积层的输入是第1层的输出，其输出为

$$Y_2(i,j) = \sum_{p=0}^{m_2-1} \sum_{q=0}^{n_2-1} Y_1(i+p,j+q)K_2(p,q) \quad (3)$$

第3个卷积层的输入为第2层的输出，其输出为

$$Y_3(i,j) = \sum_{c=1}^{C_2} \sum_{p=0}^{m_3-1} \sum_{q=0}^{n_3-1} Y_2^c(i+p,j+q)K_3^c(p,q) \quad (4)$$

式中： $Y_2^c(i,j)$  为第2个卷积层第  $c$  个通道在位置  $(i,j)$  处的值， $C_2$  为第2层输出的通道数； $K_3^c(p,q)$  为第3层卷积核第  $c$  个通道上  $p$  行  $q$  列处的权重； $m_3 \times n_3$  是第3层卷积核的尺寸； $Y_3(i,j)$  为第3层输出特征图中位置  $(i,j)$  处的值。随着层数的增加，卷积操作能够捕捉到越来越复杂的特征，低层次的卷积核可以捕捉局部的简单模式，而高层次的卷积核则能够识别更全局的模式。

最后，使用ReLU激活函数对每一层的输出进行非线性变换，能够有效提高模型的非线性表示能力。ReLU函数将所有负值输出为零，正值保持不变，有助于避免梯度消失问题。最后一层卷积层经过ReLU激活后的表达式为

$$Z_3(i,j) = \max\left(0, \sum_{c=1}^{C_2} \sum_{p=0}^{m_3-1} \sum_{q=0}^{n_3-1} Y_2^c(i+p,j+q)K_3^c(p,q)\right) \quad (5)$$

式中： $\max(\cdot)$  为取最大值函数，用于实现ReLU激活。

每层输出经过ReLU激活后得到新的特征输

出，该过程引入了非线性特性，使网络能够学习更复杂的模式。

## 1.2 CAM

在经2D CNN模块处理后，特征已经被提取为包含多个通道的高维表示。然而，不同通道对交通事故严重程度预测的重要性并不相同。为了进一步优化特征选择，本文模型引入了CAM。假设输入特征矩阵  $X$  为  $N \times C$ ，其中  $N$  为样本数量， $C$  为特征数量（即通道数），全局平均池化操作会计算每个特征的平均值

$$F_{\text{avg}}(c) = \frac{1}{N} \sum_{i=1}^N X(i,c) \quad (6)$$

式中： $F_{\text{avg}}(c)$  为第  $c$  个通道的全局平均值，表示了该特征在整个数据集中的总体趋势。

提取全局特征后，通过全连接层计算每个通道的权重。假设初始输入的通道数量为  $C$ ，第1个全连接层将通道数缩减到  $C/r$ ，其中  $r$  为超参数，用于控制降维程度。表达式为

$$A(c) = W_i \cdot F_{\text{avg}} + b_i \quad (7)$$

式中： $A(c)$  为每个通道的注意力权重，维度为  $1 \times c$ ； $W_i$  为第  $i$  个全连接层的权重矩阵； $b_i$  为第  $i$  个偏置项， $i=1,2,3$ 。

计算得到每个通道的权重后，最后一步是将这些权重应用到原始特征上，即对每个特征进行加权操作，该过程通过逐元素乘法实现。表达式为

$$F_{\text{output}}(i,j,c) = F(i,j,c)\sigma(W_2 \cdot F_{\text{ReLU}} + b_2) \quad (8)$$

式中： $F(i,j,c)$  为输入特征图的第  $c$  个通道的第  $(i,j)$  个位置的特征值； $\sigma(\cdot)$  为第  $c$  个通道的权重，为Sigmoid函数； $F_{\text{ReLU}}$  为ReLU激活后的特征表示；加权后的特征图  $F_{\text{output}}$  会更加突出对任务有帮助的特征通道，削弱无用的通道，从而减少它们对最终预测的影响。这有助于提高模型的准确性和泛化能力。

### 1.3 MHA

在完成了CAM对特征通道重要性的优化后,模型需要进一步建模不同特征之间的全局关联性,以捕捉特征之间的长距离依赖关系。为此,本文加入了MHA,通过注意力操作有效挖掘多维特征之间的复杂关系,提升模型的全局建模能力。MHA的计算方式如下

$$\mathbf{Q}_i = \mathbf{X}\mathbf{W}_{\mathbf{Q}}, \mathbf{K}_i = \mathbf{X}\mathbf{W}_{\mathbf{K}}, \mathbf{V}_i = \mathbf{X}\mathbf{W}_{\mathbf{V}} \quad (9)$$

每个头  $i$  都有自己独立的  $\mathbf{Q}$ 、 $\mathbf{K}$  和  $\mathbf{V}$  矩阵,注意力权重  $\alpha_{ij}$  的计算式如下

$$\alpha_{ij} = \frac{\exp(\mathbf{Q}_i \mathbf{K}_i^T / \sqrt{d_k})}{\sum_{j=1}^T \exp(\mathbf{Q}_i \mathbf{K}_i^T / \sqrt{d_k})} \quad (10)$$

$$\text{Head}(i) = \mathbf{A}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) = \sum_{j=1}^T \alpha_{ij} \mathbf{V}_{i,j} \quad (11)$$

式中:  $\text{Head}(i)$  为第  $i$  个头函数;  $\alpha_{ij}$  为第  $i$  个头第  $j$  个键的注意力权重;  $T$  为输入序列的长度;  $d_k$  为单个注意力头中查询向量  $\mathbf{Q}$ 、键向量  $\mathbf{K}$  的维度;  $\mathbf{A}(\cdot)$  为缩放点积注意力函数的抽象表示,是注意力计算算子;  $\mathbf{V}$  为值矩阵;  $\exp(\cdot)$  为指数函数。接着,将所有头的输出拼接在一起,并通过线性变换生成最终的输出  $\text{MultiHead}(\cdot)$ 。表达式为

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{Head}(1), \text{Head}(2), \dots, \text{Head}(h)) \mathbf{W}_{\text{output}} \quad (12)$$

式中:  $\text{Concat}(\cdot)$  为拼接输出;  $\mathbf{W}_{\text{output}}$  为拼接后的输出权重矩阵,负责将多个头的结果融合为一个输出;  $h$  为头的总数。经过MHA处理后,结果会被展平为一个向量,经过全连接层进行非线性转换,最终,输出经过  $\text{Softmax}(\cdot)$  函数,得到分类问题中每个类别的概率  $\hat{y}$ ,  $\hat{y}$  可以表示为

$$\hat{y} = \text{Soft max}(\mathbf{W}_3 \cdot \text{ReLU}(\mathbf{W}_2 \cdot \text{ReLU}(\mathbf{W}_1 \cdot \text{Flatten}(\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V})) + b_1) + b_2) + b_3) \quad (13)$$

式中:  $\text{ReLU}(\cdot)$  为ReLU激活函数;  $\text{Flatten}(\cdot)$  为展平操作。将激活函数  $\text{Soft max}(\cdot)$  添加到所提模型的输出层,用于实现最终预测。

## 2 损失函数和优化算法

本文选择分类交叉熵衡量模型的预测损失,该损失可以有效捕获模型预测概率分布与真实标签分布之间的差异。通过优化该损失函数,模型能够调整参数,使得输出的预测概率更接近真实标签分

布。分类交叉熵损失函数  $L(\cdot)$  的表达式为

$$L(y, \hat{y}) = - \sum_{i=1}^c y_i \log(\hat{y}_i) \quad (14)$$

式中:  $y_i$  为真实标签的 one-hot 编码;  $\hat{y}_i$  为模型输出的预测概率;  $\log(\cdot)$  为对数函数。分类交叉熵的目标是最大化真实标签对应的预测概率,从而最小化预测与真实值之间的差异。选择以动量和自适应学习率闻名的Adam优化器来有效地调整每个参数的学习率。

## 3 实验数据预处理及实施细节

科学合理的数据处理是提升预测模型准确性的基础。本文通过Pandas库加载数据,并对目标列“Severity”进行预处理,将事故严重程度划分为4类:1级(轻微事故)、2级(一般事故)、3级(较大事故)、4级(重大事故),数据集按6:2:2的比例划分为训练集、验证集和测试集。

### 3.1 数据清理

数据清洗是确保数据准确性和一致性的重要步骤,本研究针对美国交通事故(US-Accidents)数据集进行处理<sup>[7]</sup>。首先进行特征选择:去除与事故严重程度预测无关的特征,保留关键特征。选用的特征包括:Start\_Lat(起始纬度)、Start\_Lng(起始经度)、Temperature(温度,单位:华氏度)、Humidity(湿度,单位:百分比)、Wind\_Speed(风速,单位:英里/小时)、Weather\_Condition(天气状况)等,这些特征与预测目标Severity密切相关。其次处理缺失值:针对缺失值问题,分类特征使用目标编码(Target Encoding)处理,例如Street(街道)、City(城市)和Weather\_Condition(天气状况)。最后进行数据类型转换:将Weather\_Timestamp(天气时间戳)转换为datetime类型,并拆分为Year(年)、Month(月)、Day(日)、Hour(时)等时间特征,帮助模型捕捉时间因素对事故发生及严重程度的影响。

### 3.2 特征编码与标准化

为了使数据适配模型处理要求,对Street、City、Weather\_Condition等类别特征使用目标编码(Target Encoding)转换为数值形式,增强其对目标变量的表征能力。对Start\_Lat、Start\_Lng、Temperature等数值特征使用StandardScaler进行标准化处理,该操作将特征值映射为均值为0、标准差为1的标准分布,消除特征尺度差异对模型训练的不利影响。此外,将所有数据统一转换为float32类型,以提高

计算效率和模型稳定性,并通过断言语句检查缺失值,以确保数据清洗的完整性。处理后,数据集的最终维度为 $(N, 45)$ ,其中 $N$ 为样本数量,45为处理

后的特征数量,该数据集为后续模型训练奠定了良好基础。交通事故预测系统数据预处理流程如图2所示。

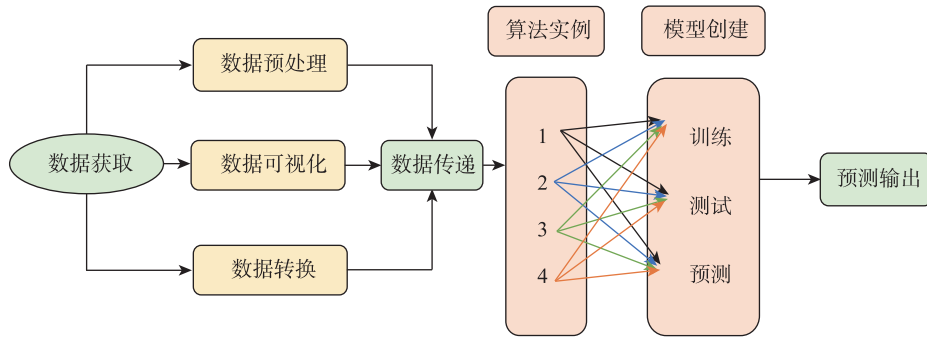


图2 交通事故预测系统数据预处理流程图

Fig. 2 Flowchart of data preprocessing for traffic accidents prediction system

## 4 实验分析

### 4.1 数据描述

为了评估模型的有效性和适用性,本研究使用US-Accidents数据集开展实验<sup>[7]</sup>。该数据集涵盖美国49个州,数据收集时间为2016年2月至2023年3月,包含46个原始特征,涵盖事故的时间、地点、天气状况、道路类型等关键信息。数据来源于多个应用程序编程接口(API),并结合了交通部门、执法机构、交通摄像头和传感器的记录。每条事故记录都包含详细信息,可用于分析事故原因及探索改善道路安全的潜在措施。数据集整体统计描述如表1所示。

表1 数据集整体统计描述

Tab.1 Description of the whole dataset

信息	全部数据
事故记录数	3 254 551
时间跨度	2016年2月—2023年3月
特征数量	46
重大事故数	103 016
较大事故数	62 285
一般事故数	3 065 840
轻微事故数	23 410

### 4.2 损失函数收敛性分析

损失函数是衡量模型预测能力的重要指标,反映了模型预测值与真实值之间的偏差。理想的损失曲线应逐渐下降并最终趋于平稳,表明模型性能

持续提升。在整个训练过程中,模型的训练损失与验证损失均呈现持续下降趋势,在大约50个训练轮次(epoch)后逐渐趋于稳定。训练损失与验证损失之间的差异较小,未出现明显过拟合现象,说明模型在训练集与验证集上的表现保持一致,具有良好的泛化能力。随着训练的进行,损失曲线整体平滑下降,表明模型能够有效学习交通事故数据中的关键特征。

### 4.3 消融实验分析

#### 4.3.1 各组成部分性能分析

表2总结了本文的消融研究结果,评估了CMHANet模型各组成部分(2D CNN、CAM、MHA)的贡献。实验基于测试集,计算了分类任务的F1分数( $F_1$ -score,  $F_1$ )、精确率(Precision,  $P$ )、召回率(Recall,  $R$ )和准确率(Accuracy,  $A$ )。添加通道注意力模块后,各项性能指标均有所提升;引入多头注意力模块后,性能进一步提升。完整CMHANet模型结合了所有模块,取得了最佳性能,验证了该综合方法对特征学习和预测能力的增强效果。这表明CAM和MHA对CNN模型具有互补作用,能显著提升事故严重性分类的预测效果。

表2 消融实验结果对比

Tab.2 Comparison of ablation experiment results

模型	$F_1$	$P$	$R$	$A$
2D CNN	0.938 9	0.940 0	0.951 3	0.951 3
CNN+CAM	0.940 6	0.940 9	0.951 6	0.951 6
CNN+MHA	0.941 4	0.941 6	0.952 0	0.952 0
CMHANet	0.959 7	0.959 8	0.961 7	0.961 7

### 4.3.2 参数分析

当学习率在 0.000 1~0.100 0 时,CMHANet 模型在  $F_1$ 、 $P$ 、 $R$  和  $A$  上均表现出色;当学习率超过 0.100 0 时,模型性能显著下降,这表明将学习率设定在适当范围内有助于模型的稳定训练和性能提升。

图 3 展示了不同丢弃率对 CMHANet 模型性能的影响。最佳丢弃率为 0.5,此时模型达到最高性能。当丢弃率增加到 0.6 或更高时,模型性能下降,表明过度正则化会削弱模型效果。总体而言,丢弃率为 0.5 时,模型表现最佳,显著提升了交通事故严重性预测的准确性和可靠性。




图 3 不同丢弃率对 CMHANet 模型性能指标的影响  
Fig. 3 Impact of different dropout rates on CMHANet model performance metrics

### 4.4 模型比较

本文采用 5 个基线模型评估了 CMHANet 模型的性能,结果表明,CMHANet 模型在各项指标上均优于其他对比模型,如表 3 所示。整体来看,在本实验中,深度学习模型的表现优于传统机器学习模型。结合 CAM 与 MHA 的 CMHANet 模型在复杂特征学习和预测性能方面表现最佳,能够为交通事故严重

表 3 不同模型预测性能对比

Tab. 3 Comparison of prediction accuracy across different models

模型	$F_1$	$P$	$R$	$A$
KNN	0.865 5	0.862 4	0.884 7	0.884 7
Decision Tree	0.896 2	0.893 3	0.912 0	0.912 0
2D CNN	0.938 9	0.940 0	0.951 3	0.951 3
DNN	0.926 7	0.928 4	0.930 6	0.930 6
CNN+CAM	0.940 6	0.940 9	0.951 6	0.951 6
CMHANet	0.959 7	0.959 8	0.961 7	0.961 7

程度预测提供更精准的解决方案,也为智能交通系统的后续开发提供参考方向。

## 5 结论

在交通事故预测中,传统方法难以有效应对高维复杂数据,实现高精度与鲁棒性的预测。为此,本文提出了基于 CNN 和注意力机制的 CMHANet 模型。该模型通过 CNN 提取空间特征,CAM 强化关键特征,MHA 捕捉特征间的复杂依赖关系,有效分析 US-Accidents 数据集数据中的关键因素,从而为准确预测事故严重程度提供了强有力的支持。为评估 CMHANet 模型的有效性,本文与 5 种基线方法(KNN、Decision Tree、2D CNN、DNN、CNN+CAM)进行了比较。

实验结果显示,CMHANet 模型在准确性和鲁棒性方面均优于传统机器学习方法,这表明 CMHANet 模型在特征提取和注意力机制方面的贡献显著。该模型通过准确预测交通事故的严重程度,为交通事故预测提供新的思路和方法。

### 参考文献:

- [1] ZAJAC S S, IVAN J N. Factors influencing injury severity of motor vehicle-crossing pedestrian crashes in rural Connecticut[J]. Accident Analysis & Prevention, 2003, 35 (3): 369-379.
- [2] ABRARI VAJARI M, AGHABAYK K, SADEGHIAN M, et al. A multinomial logit model of motorcycle crash severity at Australian intersections[J]. Journal of Safety Research, 2020, 73: 17-24.
- [3] LI Z B, LIU P, WANG W, et al. Using support vector machine models for crash injury severity analysis[J]. Accident Analysis & Prevention, 2012, 45: 478-486.
- [4] ABELLÁN J, LÓPEZ G, DE OÑA J. Analysis of traffic accident severity using decision rules via decision trees [J]. Expert Systems with Applications, 2013, 40(15): 6047-6054.
- [5] YAN M M, SHEN Y D. Traffic accident severity prediction based on random forest[J]. Sustainability, 2022, 14 (3): 1729.
- [6] MOHAMMADPOUR S I, KHEDMATI M, ZADA M J H. Classification of truck-involved crash severity: dealing with missing, imbalanced, and high dimensional safety data[J]. PLoS One, 2023, 18(3): e0281901.
- [7] GUTIERREZ-OSORIO C, GONZÁLEZ F A, PEDRAZA

- C A. Deep learning ensemble model for the prediction of traffic accidents using social media data[J]. *Computers*, 2022, 11(9): 126.
- [8] SUN Z Y, XING Y X, WANG J Y, et al. Exploring injury severity of vulnerable road user involved crashes across seasons: a hybrid method integrating random parameter logit model and Bayesian network[J]. *Safety Science*, 2022, 150: 105682.
- [9] AFSHAR F, SEYEDABRISHAMI S, MORIDPOUR S. Application of extremely randomised trees for exploring influential factors on variant crash severity data[J]. *Scientific Reports*, 2022, 12: 11476.
- [10] YANG Z K, ZHANG W P, FENG J. Predicting multiple types of traffic accident severity with explanations: a multi-task deep learning framework[J]. *Safety Science*, 2022, 146: 105522.
- [11] RAJEH T M, LI T R, LI C S, et al. Modeling multi-regional temporal correlation with gated recurrent unit and multiple linear regression for urban traffic flow prediction [J]. *Knowledge-Based Systems*, 2023, 262: 110237.
- [12] PETROVIĆ A D, BANIĆ M, SIMONOVIĆ M, et al. Integration of computer vision and convolutional neural networks in the system for detection of rail track and signals on the railway[J]. *Applied Sciences*, 2022, 12(12): 6045.
- [13] MEHDI M Z, KAMMOUN H M, BENAYED N G, et al. Entropy-based traffic flow labeling for CNN-based traffic congestion prediction from meta-parameters[J]. *IEEE Access*, 2022, 10: 16123-16133.
- [14] SATTAR K, CHIKH OUGHALI F, ASSI K, et al. Transparent deep machine learning framework for predicting traffic crash severity[J]. *Neural Computing and Applications*, 2023, 35(2): 1535-1547.
- [15] SONI S, CHOUHAN S S, RATHORE S S. TextConvoNet: a convolutional neural network based architecture for text classification[J]. *Applied Intelligence*, 2023, 53(11): 14249-14268.
- [16] WANG Y C, CHANG W, LI J J, et al. Signal processing for enhancing railway communication by integrating deep learning and adaptive equalization techniques[J]. *PLoS One*, 2024, 19(10): e0311897.
- [17] PAPPATERRA M J, PAPPATERRA M L, FLAMMINI F. A study on the application of convolutional neural networks for the maintenance of railway tracks[J]. *Discover Artificial Intelligence*, 2024, 4(1): 30.
- [18] PARVEEN N, CHAKRABARTI P, HUNG B T, et al. Twitter sentiment analysis using hybrid gated attention recurrent network[J]. *Journal of Big Data*, 2023, 10(1): 50.
- [19] YANG G L, WANG J X, NIE Z L, et al. A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention[J]. *Agronomy*, 2023, 13(7): 1824.
- [20] WU M Y, JIA H W, LUO D, et al. A multi-attention dynamic graph convolution network with cost-sensitive learning approach to road-level and minute-level traffic accident prediction[J]. *IET Intelligent Transport Systems*, 2023, 17(2): 270-284.
- [21] 严利鑫, 胡鑫辉, 刘清梅, 等. 道路交通事故严重程度预测及致因分析[J]. *华东交通大学学报*, 2024, 41(5): 65-73.
- YAN L X, HU X H, LIU Q M, et al. Road traffic accident severity prediction and causation analysis[J]. *Journal of East China Jiaotong University*, 2024, 41(5): 65-73.



通信作者:严丽平(1980—),女,教授,博士,硕士生导师,研究方向为智能交通。E-mail:csyanliping@163.com。

(责任编辑:姜红贵)