

公路货运危险驾驶行为智能预测技术研究*

柳鹏飞¹ 陆见光^{2,3} 徐磊¹ 唐向红² 刘方杰⁴

(1.贵州大学,现代制造技术教育部重点实验室,贵阳 550025;2.贵州大学,公共大数据国家重点实验室,贵阳 550025;3.重庆工业大数据创新中心有限公司,重庆 400707;4.贵州新思维科技有限责任公司,贵阳 550001)

【摘要】基于某省载货汽车历史行驶数据,提出了一种基于卷积神经网络-长短期记忆(CNN-LSTM)网络与自注意力机制的危险驾驶行为预测方法。针对载货汽车行驶数据量大、维度高、特征提取难度大、时序性强的特点,首先运用XG-Boost对特征进行筛选,接着利用卷积神经网络(CNN)进行空间特征提取,再运用长短期记忆(LSTM)网络捕捉驾驶行为的时序信息,最后通过自注意力机制对危险驾驶行为进行预测。试验结果表明,该方法相对其他长时间序列预测方法在某省公路货运驾驶数据上表现优异,识别准确率达到85.05%,加权平均召回率达到83%,F1分数(F1-Score)达到84%。

关键词:公路货运 数据驱动 自注意力机制 危险驾驶 行为预测

中图分类号:U471.15 **文献标志码:**A **DOI:** 10.19620/j.cnki.1000-3703.20230141

Research on Intelligent Prediction Technology of Dangerous Driving Behavior in Highway Freight

Liu Pengfei¹, Lu Jianguang^{2,3}, Xu Lei¹, Tang Xianghong², Liu Fangjie⁴

(1. Key Laboratory of Advanced Manufacturing Technology of the Ministry of Education, Guizhou University, Guiyang 550025; 2. State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025; 3. Chongqing Industrial Big Data Innovation Center Co., Ltd., Chongqing 400707; 4. Guizhou Xin Si Wei Technology Co., Ltd., Guiyang 550001)

【Abstract】Based on the historical driving data of trucks in a province, this paper proposed a prediction method of dangerous driving behavior based on Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM) network and self-attention mechanism. For the characteristics of large amount of truck driving data, high dimension, difficult feature extraction and strong time sequence, this method first used XGBoost to filter the features, then used CNN to extract spatial features and LSTM to further capture the temporal information of driving behaviors. Finally, dangerous driving behaviors were predicted by self-attention mechanism. Experimental results show that the method presented in this paper performs better than other long time series prediction methods on highway freight driving data in a province, with recognition accuracy reaching 85.05%, the weighted average recall rate reaches 83%, and the F1-score reaches 84%.

Key words: Highway freight, Data driven, Self-attention mechanism, Dangerous driving behavior, Prediction of driving behavior

【引用格式】柳鹏飞,陆见光,徐磊,等.公路货运危险驾驶行为智能预测技术研究[J].汽车技术,2024(3):56-62.

LIU P F, LU J G, XU L, et al. Research on Intelligent Prediction Technology of Dangerous Driving Behavior in Highway Freight[J]. Automobile Technology, 2024(3): 56-62.

1 前言

随着物流产业的快速发展,公路运输成为我国主要的货运物流方式之一^[1]。载货汽车数量的增加也导致了交通运输业成为我国每年事故死亡人数最多的行业,载

货汽车超载、追尾、疲劳驾驶等现象严重^[2],对公路交通安全造成了极大威胁。因此,如何在事故发生前利用载货汽车车载装置记录的驾驶数据对危险驾驶行为进行预警显得尤为重要。

针对上述问题,现有研究分为驾驶员驾驶行为识别

*基金项目:贵州省科技支撑计划项目(QKHZC[2022]YB074)。

通信作者:陆见光(1986—),博士,副教授,主要研究方向为大数据与智能制造,jglu@gzu.edu.cn。

模型和车辆预警模型两个方面。张俊^[3]等对驾驶员视频监控数据进行离线分析,建立驾驶员驾驶行为识别预测模型。Katare^[4]等将车载雷达感知到的加速度、速度和分离距离等输入人工神经网络,向驾驶员发出可能碰撞的警报。上述研究基于车辆、驾驶员状态信息进行建模,为车辆行驶安全提供预警,但均未涉及利用车联网下载货车车载装置记录信息提升公路交通安全。

依赖于采集到的车辆驾驶数据量的不断扩充,基于行驶数据的载货汽车驾驶行为分析成为可能。本文针对车联网中载货汽车驾驶数据集,利用卷积神经网络(Convolutional Neural Network, CNN)^[5]和长短期记忆(Long Short-Term Memory, LSTM)^[6]网络对具有复杂相关性的驾驶数据进行时空特征提取,并提出一种复合高斯误差线性单元(Gaussian Error Linear Unit, GELU)和Sigmoid损失函数与多重自注意力模块^[7],进一步提高模型对特征的提取能力。

2 基于CNN-LSTM与MSE_GS的载货汽车驾驶行为预测方法

公路载货汽车行驶的历史数据是典型的长时间序列,其数据量大、维度高,且空间与时间关联性强,特征提取难度大。因此,本文采用CNN和LSTM相结合的方法提取空间与时间特征。首先,CNN中卷积核能有效融合多个特征并生成更高层次特征,还可以提取数据空间特征,利用全局平均池化抑制过拟合,为防止数据量堆积产生的数值爆炸问题,在每一个卷积层后增加1个批标准化层。其次,将CNN所提取的特征作为LSTM中的输入继续训练,采用多个不同记忆体捕捉其时序特征。

由于驾驶数据特征的非线性较强,若只用CNN-LSTM对模型进行训练,将导致网络模型对非线性特征提取能力不足。针对这一问题,本文在CNN-LSTM中引入多重自注意力机制来提高非线性特征的提取能力。由于多重自注意力模块在神经网络的全连接层之后,故不需要添加全局池化,可以减少模型欠拟合的发生^[8]。同时为了抑制过拟合,在多重自注意力模块中引入随机正则思想,将激活函数改为高斯误差线性单元(Gaussian Error Linear Units, GELU)。因此,为了提取数据中的非线性特征,提高网络模型对非线性特征的拟合能力,进而提高模型准确性,本文提出一种基于GELU和Sigmoid损失函数的多重自注意力模块(Multiple Squeeze- and- Excitation based on GELU and Sigmoid, MSE_GS),其网络结构如图1所示。其中,输入特征维

度 F 经过3个全连接层先后变为 $F/16$ 、 $F/4$ 和 F ,激活函数分别为GELU、GELU和Sigmoid。将全连接层的权重与输入特征相乘得到最后输出。




图1 自注意力机制示意

综上,本文提出一种基于CNN-LSTM与MSE_GS的载货汽车驾驶行为预测方法,其流程如图2所示,图3所示为该方法的网络结构示意图。

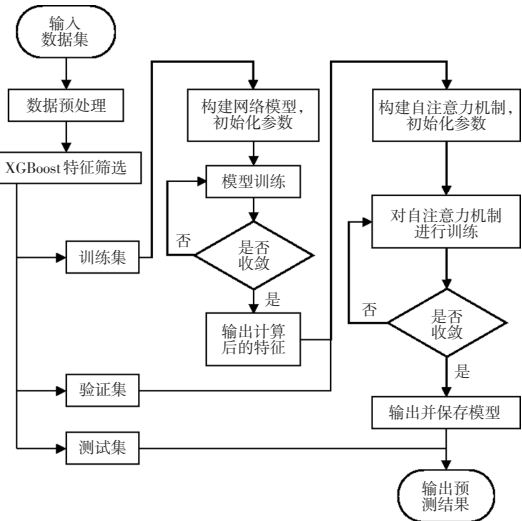


图2 载货汽车驾驶行为预测方法流程




图3 基于CNN-LSTM与MSE_GS网络结构示意图

3 试验及结果分析

3.1 试验数据及试验环境

本文数据来源于某省车联网企业提供的2021年5~6月,17 659位驾驶员共计3 241 595条驾驶数据。数据通过车载高级辅助驾驶系统(Advanced Driver Assistant

System, ADAS)采集,触发报警时数据将被上传至车联网公司数据库。在30个原始字段中,剔除企业平台业务通信数据(如头标识、校验码等),剔除重复性数据(如报警类型与报警二进制字符串、车牌号与车辆平台ID、设备ID之间的重复)。考虑到所需数据均为载货汽车驾驶员的驾驶数据,故剔除经营范围、行业类型字段。因此,本文所使用的字段内容如表1所示。数据选定后对空数据、异常值数据进行处理。鉴于数据量大,故对空数据、异常值数据进行剔除操作,剩余数据量为2 335 593条,满足本文试验所需数据量。

表1 本文所选字段

字段名称	数据类型	字段说明
gps time	TIMESTAMP	上报时间戳
latitude	NCHAR	经度
longitude	NCHAR	纬度
total mileage	INT	总里程
direction	INT	车头方向
altitude	INT	海拔
alarm	INT	报警类型
speed	INT	行驶记录速度
vehicle nationality	INT	车籍地
plate color	INT	车牌颜色
str status	NCHAR	状态二进制字符串
vehicle type code	INT	车辆类型

其中,报警类型“alarm”作为驾驶数据的标签,能够直接反映驾驶行为的特征。单个报警信息定义来自于我国交通运输部颁布的《道路运输车辆卫星定位系统终端通信协议及数据格式》中报警预警标志位定义。载货汽车触发报警时车载设备向车联网公司终端发送报警信息,经二进制编码后车联网公司记录其报警内容并采取相应对策。单个报警类信息共29种,剔除如“终端电压欠压报警”“终端电源掉电报警”等与道路安全相关度较小的报警信息,并从数据库汇总筛选出报警频率相对较高的17类复合报警信息,如表2所示。

根据报警信息危害程度不同,将驾驶行为划分为低风险和高风险2类。若报警信息中至少含有超速、疲劳、碰撞侧翻、累计驾驶超时、右转盲区中的一个,则该驾驶行为被定义为高风险,因为一旦发生事故,必然会造成极大生命财产损失。其余报警信息所表示的驾驶行为被定义为低风险。

3.2 特征筛选

特征选择也称为属性选择,是从原始特征中选择一些有效特征来降低数据维度的过程^[9]。本文采用的是常

见特征选择方法中的过滤式(Filter)方法。其主要思想是先进行特征选择,再训练学习器,特征选择的过程与学习器无关,对每一维特征赋予权重,代表其重要性,然后依据权重排序。运用XGBoost算法进行特征筛选,其主要特点有:具有良好的防止过拟合特性;拥有较高的计算效率;计算过程中有一定的启发性。

表2 报警信息

报警编码	报警信息	类别编号	报警编码	报警信息	类别编号
16109 40416	超速	0	32212 91008	超速、违规驾驶	9
32212 25476	超速、碰撞侧翻	1	21475 49184	违规驾驶	10
40269 98784	超速、疲劳、累计驾驶超时	2	32212 25474	超速驾驶、侧翻	11
21474 95936	累计驾驶超时、超时停车	3	21474 00032	右转盲区异常	12
24159 84640	危险驾驶行为(电话、吸烟)	4	26843 54562	疲劳驾驶、侧翻	13
21474 83664	车辆非法点火	5	21475 49188	违规行驶、碰撞侧翻	14
21516 79488	进出区域、进出路线	6	21474 84416	路段行驶时间不足/过长、路线偏移	15
21474 89792	超时停车、进出区域	7	21474 83656	车辆非法位移	16
21474 84160	路线偏离	8			

根据表1中所选字段内容,将不属于同一量纲的数据进行标准化处理,转化为无量纲数据,对不便于分析的字段进行独热编码操作。以字段报警“alarm”为标签 y ,其他字段内容为输入量 x ,将所选特征输入XGBoost进行特征选择。特征重要性排序用来衡量特征在构建决策树时的价值,特征价值的高低体现了该特征对于驾驶行为影响的重要性。对每个属性进行特征重要性计算,在单一决策树中以该属性为分裂点计算分裂前、后模型性能变化,性能度量一般选择基尼(Gini)系数作为指标,将所有决策树的结果进行加权平均得到重要性得分。图4所示为各特征对标签“alarm”的重要性,只保留对标签影响最大的6个特征,降低输入神经网络的维度,可以提高神经网络的计算效率。

试验保留的特征为总里程数(Total Mileage)、经纬度(Latitude, Longitude)、车籍地(Vehicle Nationality)、行驶记录速度(Speed)、上报时间戳(GPS Time)6个特征。总里程数对标签“alarm”的重要性最强,里程越长,遭遇危险的可能性越高,长时间行车必然会影响驾驶员的判断,超速、疲劳、累计驾驶超时等会造成较为严重的生命

财产损失;经纬度对固定位置的报警类型影响较大,侧翻、违停、视野盲区等报警常发生在固定路段;车籍地与车辆进出区域、进出路线、路线偏移这类报警相关性较强;行驶记录速度主要影响超速、车辆非法位移类报警,超速报警最直接的判断标准是行驶记录速度;上报时间戳为载货汽车行驶的时间信息,长时间行车与夜间行车对疲劳、累计驾驶超时、危险驾驶行为等报警类型影响较大,危害较高。




图4 特征重要性排序


在2 335 593条数据中,保留上述6个特征与标签,再按照7:3分别划分成测试集与验证集。以表2中的类别编号作为标签,取0~16共17类。

3.3 CNN-LSTM 模块参数选择


为了研究激活函数对预测结果的影响,本文对Sigmoid、ReLU和双曲正切函数(Tanh函数)3种激活函数进行试验,结果如表3所示。为避免试验结果受到随机因素的影响,每次测试均进行10次试验取平均准确率。图5所示为10次试验中模型收敛稳定时不同激活函数对比的平均结果,模型迭代次数以训练至网络收敛为准。可以看出,ReLU激活函数在准确率(Accuracy)、损失率(Loss)和稳定性方面均比Sigmoid与Tanh函数更适合。

表3 不同激活函数的准确率 %

激活函数	平均准确率
ReLU	85.05
Sigmoid	83.24
Tanh	81.05



(a)准确率




(b)损失率

图5 不同激活函数迭代对比


为了研究优化器对预测结果的影响,本文对自适应矩估计(Adaptive moment estimation, Adam)、随机梯度下降(Stochastic Gradient Descent, SGD)和均方根传递(Root Mean Square prop, RMSprop)3种优化器进行试验,结果如表4所示。图6所示为3种优化器模型收敛示意。为保证试验准确性,取10次重复试验准确率平均值作为最终结果。设计优化器的激活函数均为ReLU,迭代次数以训练至网络收敛或损失率不再下降为准,学习率为0.003。可以看出,在相同激活函数与学习率条件下,Adam有着相较于SGD与RMSprop更稳定与更高的准确率。故本文试验采用Adam作为优化器。

表4 不同优化器下模型准确率 %

优化器	平均准确率
Adam	85.05
SGD	79.50
RMSprop	80.50



(a)准确率



(b)损失率

图6 不同优化器对比

综上所述,设置CNN-LSTM网络模块中激活函数为

ReLU,优化器为Adam,学习率为0.003。

3.4 消融试验

本文消融试验组将提出的MSE_GS模型与不引入多重自注意力机制的CNN-LSTM模型、CNN以及LSTM模型进行比较。在车联网公司提供的数据集上,迭代伦次为1 000,计算各自的准确率和损失率。各消融试验组的准确率及损失变化曲线如图7所示。




图7 消融试验组在测试集上的准确率及损失率曲线

从图7a中可以看出,MSE_GS相较于CNN-LSTM准确率提升1.5%,相较于CNN准确率提升了2%,并且没有出现拟合现象。而LSTM模型的准确率则在训练初期出现大幅下降问题,但是LSTM模型损失率下降最快,并将损失率降至消融试验组最小,MSE_GS模型与CNN-LSTM模型在损失率方面的表现一致。在损失率相差0.026的情况下,MSE_GS准确率比LSTM准确率提升3%。

图8所示为MSE_GS与普通CNN-LSTM在测试集上的混淆矩阵。可以直观看出,CNN-LSTM模型在预测准确率方面相较于本文提出的MSE_GS模型有待进一步加强。

表5所示为消融试验组在测试集上的结果,其中*T*为训练时间。从表5中可以看出,MSE_GS模型在精度*P*、召回率*R*、F1分数上整体水平平均高于其他模型。在训练时间方面:CNN训练时间短,但由于其对时序不敏感,导致其他评价指标低于MSE_GS模型;LSTM不仅训练时间长,而且在其他评价指标方面整体低于MSE_GS模型。

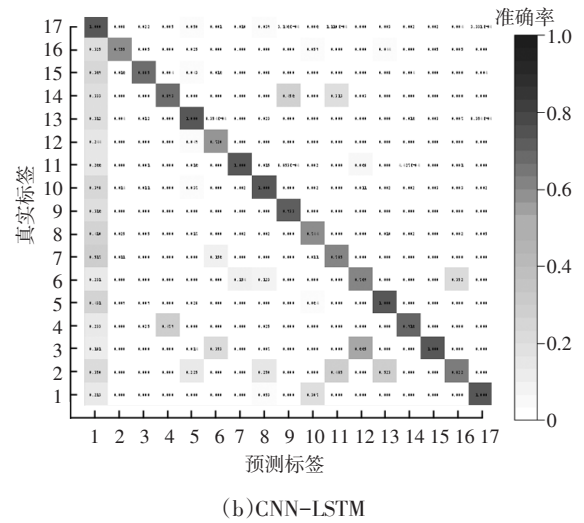
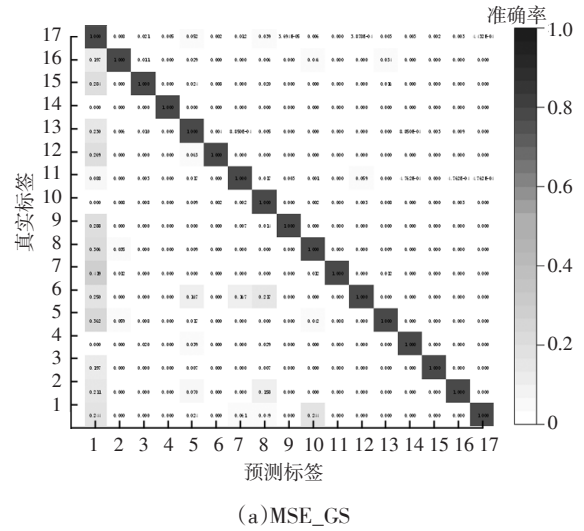


图8 MSE_GS与CNN-LSTM在测试集上的混淆矩阵

综上所述,在消融试验组中,本文提出的MSE_GS模型因引入多重自注意力机制,特征拟合能力得到进一步提高,相较于传统CNN-LSTM模型预测准确率得到进一步提高。

3.5 对比试验

为验证本文提出的方法在准确预测载货汽车公路运输时报警类型的有效性,基于本文试验中数据规模大且数据为长时间序列的特点,选取文献[10]、文献[11]、文献[12]和文献[13]的方法作为对比试验组,这些方法均采用CNN-LSTM及其改进模型。为了避免试验结果受到随机因素的影响,每次测试均进行10次重复性试验,计算出模型的平均准确率及其标准差,试验结果如表6所示。

由表6可以看出,本文所提出的模型相较于其他4种算法具有明显优势,平均预测准确率达到85.05%,标准差达到0.000 977,为对比试验中最小,说明其在长时间大规模数据集的应用中具有较好的稳定性。


表5 各试验组在测试集上的结果

组别	MSE_GS				CNN-LSTM				CNN				LSTM			
	P	R	F1分数	T	P	R	F1分数	T	P	R	F1分数	T	P	R	F1分数	T
1	0.86	0.97	0.91	4 h 44 min	0.86	0.87	0.81	5 h	0.84	0.88	0.81	2 h 30 min	0.88	0.82	0.8	10 h 25 min
2	0.77	0.46	0.47		0.54	0.31	0.32		0.55	0.5	0.44		0.51	0.45	0.49	
3	0.74	0.63	0.61		0.65	0.56	0.56		0.71	0.58	0.65		0.43	0.28	0.35	
4	0.73	0.75	0.25		0.39	0.11	0.17		0.42	0.22	0.17		0.37	0.4	0.25	
5	0.76	0.63	0.42		0.69	0.27	0.4		0.73	0.2	0.3		0.51	0.4	0.46	
6	0.78	0.35	0.45		0.73	0.29	0.41		0.68	0.23	0.36		0.55	0.41	0.49	
7	0.78	0.79	0.78		0.76	0.71	0.75		0.73	0.71	0.75		0.68	0.66	0.7	
8	0.8	0.74	0.65		0.65	0.21	0.32		0.62	0.26	0.34		0.5	0.38	0.42	
9	0.79	0.86	0.8		0.69	0.75	0.75		0.73	0.75	0.75		0.81	0.83	0.79	
10	0.69	0.84	0.75		0.61	0.5	0.57		0.62	0.75	0.76		0.56	0.6	0.57	
11	0.75	0.84	0.75		0.61	0.74	0.7		0.66	0.74	0.68		0.55	0.69	0.64	
12	0.88	0.74	0.67		0.68	0.54	0.21		0.68	0.52	0.61		0.48	0.52	0.48	
13	0.68	0.44	0.5		0.61	0.4	0.45		0.53	0.28	0.39		0.56	0.59	0.46	
14	0.87	0.44	0.57		0.73	0.38	0.49		0.68	0.24	0.38		0.63	0.47	0.54	
15	0.8	0.7	0.76		0.76	0.61	0.69		0.81	0.5	0.55		0.78	0.68	0.74	
16	0.91	0.56	0.69		0.62	0.21	0.24		0.54	0.15	0.21		0.44	0.31	0.35	
17	0.72	0.64	0.67		0.66	0.58	0.59		0.59	0.58	0.58		0.51	0.47	0.49	


图9所示为上述对比模型在测试集上的准确率及损失变化曲线。从图9中可以直观地看出,本文所提出的算法在准确率与损失率变化中均具有较好表现。这是因为在长时间序列数据预测中,若只针对时空特征的提取使用CNN-LSTM模型将会导致模型对非线性特征学习不足,丢失原数据中的部分特征,导致预测率下降,本文利用改进注意力机制,提高了模型对非线性特征的学习能力。

表6 不同算法对比试验结果

算法模型	平均准确率	准确率标准差/ $\times 10^{-3}$
MSE_GS	0.850 5	0.977
文献[10]	0.839 3	2.054
文献[11]	0.841 4	2.233
文献[12]	0.820 7	4.862
文献[13]	0.849 5	1.106



(a)准确率



(b)损失率

图9 对比模型在测试集上的准确率及损失变化曲线

4 结束语

本文面向车联网公路货运驾驶数据,使用基于CNN-LSTM与MSE_GS的货车驾驶行为识别方法,实现了公路货车报警类型预测。试验结果表明,通过引入复合GELU和Sigmoid损失函数下多重自注意力的深度学习模型,能够提高模型对长时间序列数据的特征提取能力。通过消融试验对比,相比传统CNN-LSTM、CNN、LSTM深度学习算法,本文所提出的算法在2 335 593条数据上平均准确率更高,达到85.05%,加权平均召回率、F1分数分别为83%、84%。通过对比试验,与现有长时间序列模型算法相比,准确率至少提高1.4%,表现出了最优的综合性能。

但是当前所利用模型的超参数依然需要通过大量试验手动调整,此外,因为数据规模大等问题导致模型训练时间依旧较长,后续工作是研究如何在大规模长时间序列数据条件下,在提高预测准确率的同时利用算法实现超参数自适应寻优,缩短模型训练时间。

参 考 文 献

- [1] 甘蜜,卿三东,刘晓波,等.货车轨迹数据在公路货运系统中应用研究综述[J].交通运输系统工程与信息,2021,21(5):91-101.
GAN M, QING S D, LIU X B, et al. Review on Application of Truck Trajectory Data in Highway Freight System[J]. Journal of Transportation Systems Engineering and Information Technology, 2021, 21(5): 91-101.
- [2] HELAI H, CHOR C H, HOCK H A H. Effect of Red Light Cameras on Accident Risk at Intersections[J]. Transportation Research Record: Journal of the Transportation Research Board, 2006, 1969(1): 18-26.
- [3] 张俊.基于车联网数据的驾驶行为识别与风险评估方法研究[D].合肥:中国科学技术大学,2020.
ZHANG J. Study on Driving Behavior Recognition and Risk Assessment Based on Internet of Vehicle Data[D]. Hefei: University of Science and Technology of China, 2020.
- [4] KATARE D, EL-SHARKAWY M. Embedded System Enabled Vehicle Collision Detection: An ANN Classifier [C]// 2019 IEEE 9th Annual Computing and Communication Workshop and Conference (CCWC). Las Vegas, NV, USA: IEEE, 2019: 284-289.
- [5] 孙浩,陈进,雷琳,等.深度卷积神经网络图像识别模型对抗鲁棒性技术综述[J].雷达学报,2021,10(4):571-594.
SUN H, CHEN J, LEI L, et al. Adversarial Robustness of Deep Convolutional Neural Network-Based Image Recognition Models: A Review[J]. Journal of Radars, 2021, 10(4): 571-594.
- [6] CHRISTOPHE F. Learning Algorithm Recommendation Framework for IS and CPS Security: Analysis of the RNN, LSTM, and GRU Contributions[J]. International Journal of Systems and Software Security and Protection (IJSSSP), 2022, 13(1): 1-23.
- [7] 张宸嘉,朱磊,俞璐.卷积神经网络中的注意力机制综述[J].计算机工程与应用,2021,57(20):64-72.
ZHANG C J, ZHU L, YU L. Review of Attention Mechanism in Convolutional Neural Networks[J]. Computer Engineering and Applications, 2021, 57(20): 64-72.
- [8] HENDRYCKS D, GIMPEL K. Gaussian Error Linear Units (GELUs)[EB/OL]. (2020-07-08)[2023-04-07]. <https://arxiv.org/abs/1606.08415v4>.
- [9] 李占山,刘兆赓.基于XGBoost的特征选择算法[J].通信学报,2019,40(10):101-108.
LI Z S, LIU Z G. Feature Selection Algorithm Based on XG-Boost[J]. Journal on Communications, 2019, 40(10): 101-108.
- [10] BOGAERTS T, MASEGOSA A D, ANGARITA-ZAPATA J S, et al. A Graph CNN-LSTM Neural Network for Short and Long-Term Traffic Forecasting Based on Trajectory Data[J]. Transportation Research Part C, 2020, 112: 62-77.
- [11] YUSUF S A, ALSHDADI A A, ALASSAFI M O, et al. Predicting Catastrophic Temperature Changes Based on Past Events via a CNN-LSTM Regression Mechanism[J]. Neural Computing and Applications, 2021.
- [12] 付加胜,刘伟,韩霄松,等.基于CNN-LSTM融合网络的溢流早期预测深度学习新方法[J].石油机械,2021,49(6):16-22.
FU J S, LIU W, HAN X S, et al. CNN-LSTM Fusion Network Based Deep Learning Method for Early Prediction of Overflow[J]. China Petroleum Machinery, 2021, 49(6): 16-22.
- [13] 张鹏,杨涛,刘亚楠,等.基于CNN-LSTM的QAR数据特征提取与预测[J].计算机应用研究,2019,36(10):2958-2961.
ZHANG P, YANG T, LIU Y N, et al. Feature Extraction and Prediction of QAR Data Based on CNN-LSTM[J]. Application Research of Computers, 2021, 49(6): 16-22.

(责任编辑 斛 畔)

修改稿收到日期为2023年4月7日。