

【工程与技术研究】

# 基于 CNN-LSTM 的重型自卸车侧翻预警模型

汪佳铭, 胡明茂, 师国东, 朱天民

(湖北汽车工业学院 机械工程学院, 湖北 十堰 442000)

**摘要:**为解决重型自卸车的侧翻预警问题,基于 CNN-LSTM 神经网络构造了重型自卸车的侧翻预警模型。利用 Trucksim 与 MATLAB/Simulink 搭建了重型自卸车仿真模型,以横向载荷转移率等于 $\pm 0.85$ 为侧翻阈值,提取了不同工况下的车辆运行参数,利用车辆运行参数,训练 CNN-LSTM 重型自卸车侧翻预警模型,并分别与基于 CNN、LSTM 搭建的预警模型对比。结果表明:CNN-LSTM 重型自卸车侧翻预警模型预测准确率为 98.31%;感受性曲线的曲线下面积为 0.999,高于由单一神经网络所搭建的侧翻预警模型。

**关键词:**重型自卸车;CNN-LSTM 神经网络;横向载荷转移率;侧翻预警模型;仿真

**中图分类号:** U 469.4      **文献标识码:** A      **DOI:**10.13486/j.cnki.1673-2618.2024.02.012

## 0 引言

重型自卸车因轴数少、轴距短、操纵灵活、运输周期短等特点,受到交通运输市场的青睐,但同时,重型自卸车的质心较半挂车更高,加上其行驶的路况更为复杂,因此在运输过程中发生侧翻事故的比例明显高于其他运输车辆。近年来我国发生重型自卸车侧翻事故的比例有所升高<sup>[1]</sup>。因此,有必要对重型自卸车的防侧翻预警开展更为深入的研究。

针对不同类型车辆的侧翻,国内外学者已经有了许多较为深入的研究。Hou 等<sup>[2]</sup>提出了一种基于牵引车和挂车综合侧倾角的新型侧翻指标,由于可测性差,采用无迹卡尔曼滤波(Unscented Kalman Filter, UKF)算法分别对履带和挂车的侧倾角进行估计,并在侧翻指标中考虑了不同的权重系数,以消除牵引车与挂车之间相互耦合的影响,提高了预警的准确性。Miyamoto 等<sup>[3]</sup>提出了一种基于改进前后轮转向的防侧翻控制方案,并进行了数值模拟,证明了所提出控制方案的实用性。于志新等<sup>[4]</sup>研究了基于重型车辆的动力学模型的侧翻时间(time to rollover, TTR)预警算法,并引用差动制动的方法对重型车辆进行了主动侧倾控制,有效提高了重型车辆稳定性。李胜琴等<sup>[5]</sup>主要针对客车的侧翻问题,在前人研究的基础上提出了防侧翻集成控制策略,该策略能有效控制客车在行驶过程中发生侧翻。康小鹏等<sup>[6]</sup>根据客车不同的运行状态提出了一种主动防侧翻控制方法,在现有比例积分微分控制(proportional-integral-derivative control, PID)的基础上进一步设计了柔性 PID 控制器,提高了客车在行驶过程中的稳定性,降低了客车发生侧翻的概率。Lu 等<sup>[7]</sup>针对重型车辆的侧翻风险,提出了一种基于多路面附着系数辨识的自适应侧翻预测

收稿日期:2023-06-20

基金项目:湖北省重点研发计划项目(2020BAA005);工信部工业互联网创新发展工程项目(TC200A00W, TC200802C)

第一作者简介:汪佳铭(1996—),男,湖北天门人,硕士研究生,主要从事车辆稳定性控制研究。

E-mail:1873567843@qq.com

通信作者简介:胡明茂(1980—),男,山东临朐人,教授,博士,主要从事车辆稳定性控制研究。

E-mail:hu@huat.edu.cn

控制算法,并通过实验验证了控制效果,该控制算法能够准确预测侧翻风险,及时控制侧翻。姚嘉凌等<sup>[8]</sup>提出一种基于机器学习和神经网络的侧翻预警方法,该法能有效地预测车辆行驶运动状态和运动参数,为车辆防侧翻提供了理论依据。Jin 等<sup>[9]</sup>提出一种新的三轴客车侧翻指标,通过 Trucksim 进行了验证并讨论车辆侧翻动力学的影响规律以探究其稳定性机理,结果表明,新的建模方法能够精确地描述所研究客车的侧翻动力学特性,为提高三轴客车的抗侧翻能力提供了理论依据。

神经网络具较强的鲁棒性和容错率,且处理问题快,计算迅速,自学习、自组织、自适应性强,具有很强的综合信息处理能力。而神经网络算法中,长短期记忆神经网络(Long Short-Term Memory Neural Network, LSTM)擅长对序列信息进行建模,在序列建模问题上有一定优势,具有长时记忆功能,能解决长序列训练过程中梯度消失和梯度爆炸的问题,对随时间变化的货车侧翻数据模型有很好的拟合效果。因此,本文应用神经网络对重型自卸车运行过程中的相关参数进行分析,训练好模型之后对采集的实时数据进行预测。研究结果可以为重型自卸车司机提供侧翻预警,方便其更好地处理可能发生的车辆侧翻情况,保障重型自卸车的正常行驶,减少安全隐患。

### 1 影响重型自卸车侧翻的主要因素

重型自卸车侧翻是一种极端工况。发生侧翻的影响因素主要可以归纳为两类:

- (1) 车辆本身设计的静态参数,例如质心高度、悬架类型、轮胎类型等;
- (2) 车辆行驶过程中的动态参数,例如侧向加速度、横摆角速度、质心侧偏角等<sup>[10]</sup>。

通过分析以往的重型自卸车侧翻事故可知,横摆角速度、侧倾角、侧向加速度、质心侧偏角和横向载荷转移率(Lateral-load Transfer Rate, LTR)这 5 个动态参数最能反映车辆侧倾稳定性<sup>[11]</sup>。由于重型自卸车的质心相较于一般车辆更高且其行驶路况多为松软地面,所以相较于其他类型的车辆,重型自卸车往往更容易发生侧翻。因此需要控制重型自卸车的轮胎与地面之间的载荷。本文选择以重型自卸车的 LTR 作为稳定性指标,其计算公式为

$$L_{tr} = (\sum (F_{r,i} - F_{l,i})) / (\sum (F_{r,i} + F_{l,i}))。$$

式中,  $F_{r,i}$  为作用于第  $i$  个右轮上的垂直载荷,  $F_{l,i}$  为作用于第  $i$  个左轮上的垂直载荷,  $L_{tr}$  为横向载荷转移率,其取值范围为  $[-1, +1]$ ,当  $L_{tr}$  为临界值  $\pm 1$  时,判定车辆已经开始发生侧翻。

### 2 车辆仿真模型搭建与数据预处理

#### 2.1 重型自卸车仿真模型搭建

通过查阅实车资料,确定车辆主要参数后,利用 Trucksim 动力学仿真软件搭建车辆仿真模型(图 1)。

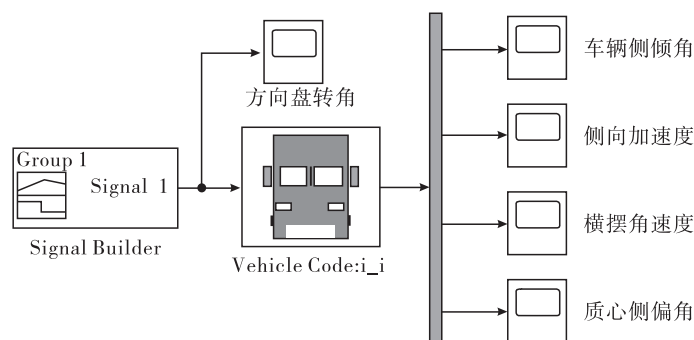


图 1 重型自卸车仿真模型

重型自卸车整车模型的搭建过程主要由 4 部分组成,分别为搭建簧上质量模型、搭建轮胎模型、搭建悬架系统、搭建转向系统。

重型自卸车仿真模型的主要参数如表 1<sup>[12]</sup>所示:

表 1 重型自卸车仿真模型主要参数

仿真模型参数	数值	仿真模型参数	数值
整车质量 $m/\text{kg}$	11 200	后悬等效侧倾阻尼 $c_{sr}/(\text{N} \cdot (\text{m} \cdot \text{s}^{-1})^{-1})$	18 200
簧上质量 $m_s/\text{kg}$	10 000	轮胎弹性系数 $k_t/(\text{N} \cdot \text{m}^{-1})$	850 000
左前、右前簧下质量 $m_{u1}, m_{u2}/\text{kg}$	200	前轮等效侧偏刚度 $k_{sf}/(\text{N} \cdot \text{rad}^{-1})$	150 000
整车绕 $x$ 轴的转动惯量 $I_x/(\text{kg} \cdot \text{m}^2)$	8 257	后轮等效侧偏刚度 $k_{sr}/(\text{N} \cdot \text{rad}^{-1})$	350 000
整车绕 $y$ 轴的转动惯量 $I_y/(\text{kg} \cdot \text{m}^2)$	101 672	侧倾臂长 $h_s/\text{m}$	0.8
整车绕 $z$ 轴的转动惯量 $I_z/(\text{kg} \cdot \text{m}^2)$	90 112	前轮距 $T_f/\text{m}$	2.03
前轮等效侧倾刚度 $k_{sf}/(\text{N} \cdot \text{m}^{-1})$	360 000	后轮距 $T_r/\text{m}$	1.863
后轮等效侧倾刚度 $k_{sr}/(\text{N} \cdot \text{m}^{-1})$	780 000	前轴距 $a/\text{m}$	3.6
前悬等效侧倾阻尼 $c_{sf}/(\text{N} \cdot (\text{m} \cdot \text{s}^{-1})^{-1})$	12 000	后轴距 $b/\text{m}$	1.4

2.2 数据的建立

将表 1 中所列数据输入系统并导入 Trucksim 动力学软件中生成车辆仿真模型, 然后与 Matlab/Simulink 进行联合仿真。以  $L_{tr} = \pm 0.85$  为侧翻阈值, 当车辆  $L_{tr}$  值处于  $[-0.85, +0.85]$  区间内时, 数据标签贴为 0, 表示无侧翻趋势; 当车辆  $L_{tr}$  值处于  $[-0.85, +0.85]$  区间外时, 数据标签贴为 1, 表示车辆有侧翻趋势, 将联合仿真产生的数据和数据标签一并导出。原始数据由鱼钩工况、双移线工况和阶跃工况 3 种常见的侧翻工况生成。将 Trucksim 的自卸车模型导入 Simulink, 设置 Trucksim 模型的输出, 得到 3 组数据。鱼钩工况、双移线工况、阶跃工况的参数设置: 路面附着系数均为 0.85, 侧翻阈值均为  $\pm 0.85$ , 初始速度分别为 85 km/h、125 km/h、75 km/h。

鱼钩工况下, 系统方向盘转角参数输入如图 2(a)所示, 数据采样频率为 0.01 s, 采样时间为 15 s, 样本数量为 1500 组。图 2(b)~(e)分别为在鱼钩工况下重型自卸车的侧倾角、侧向加速度、横摆角速度、质心侧偏角随时间的变化情况。

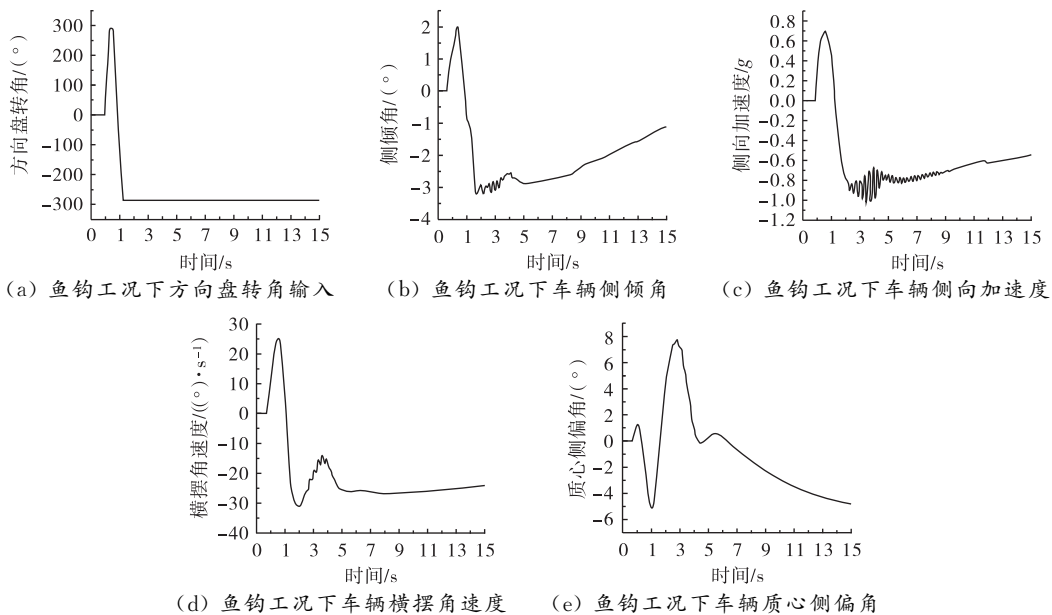


图 2 鱼钩工况参数变化情况

双移线工况下, 系统方向盘转角参数输入设置如图 3(a)所示, 数据采样频率为 0.01 s, 采样时间为

15 s, 样本数量为 1500 组。图 3(b)~(e) 分别为双移线工况下重型自卸车的侧倾角、侧向加速度、横摆角速度、质心侧偏角随时间的变化情况。

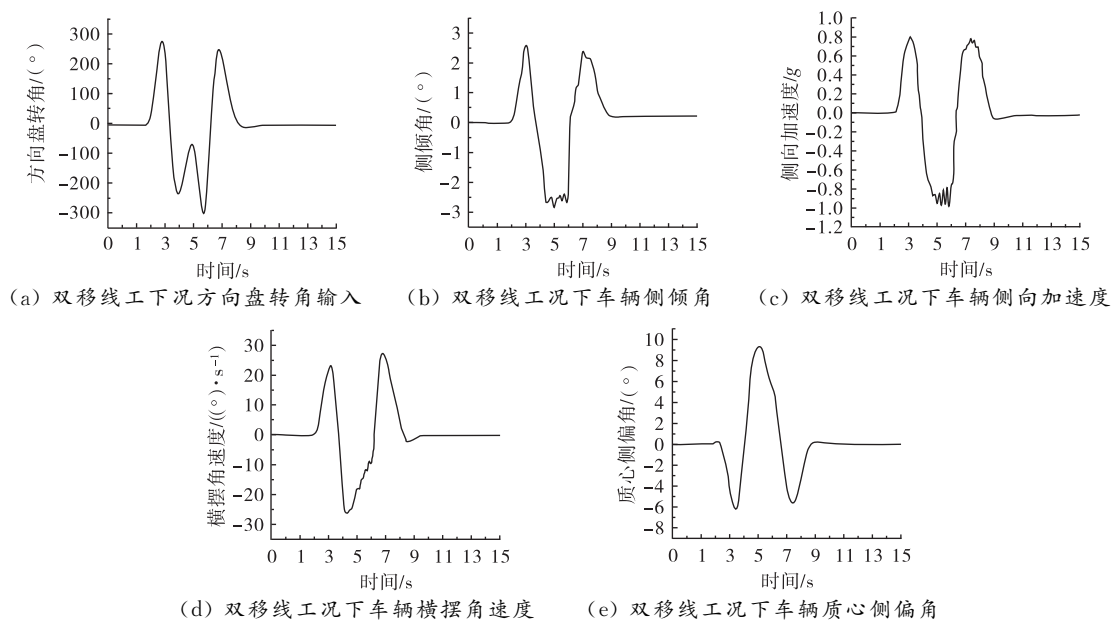


图 3 双移线工况参数变化情况

阶跃工况下, 系统方向盘转角参数输入设置如图 4(a) 所示, 数据采样频率为 0.01 s, 采样时间为 15 s, 样本数量为 1500 组。图 4(b)~(e) 分别为阶跃工况下重型自卸车的侧倾角、侧向加速度、横摆角速度、质心侧偏角随时间的变化情况。




图 4 阶跃工况参数变化情况

### 2.3 数据预处理

将上述 3 种工况共 4500 组数据导出后, 利用 Python 中的 pandas 库对数据进行预处理, 读取所采集的数据, 然后将 3 种不同工况的数据合并为一个数据矩阵, 最后对各参数做基本统计, 数据统计情况如表 2 所示。横摆角速度、侧倾角、侧向加速度、质心侧偏角 4 个参数的样本总量均为 4500, 无明显异常值和缺

失值, 无须对数据进行增删改等处理。但数据范围波动较大且单位不一致, 为方便后续预警模型的搭建, 需要对数据进行无量纲化处理。目前主流数据无量纲化处理有归一化和标准化两种, 考虑到本文数据部分参数最大值和最小值相差较大, 容易造成归一化结果不稳定, 从而导致侧翻预警模型训练效果变差, 故本文采用标准化作为数据无量纲处理的方法。将数据以均值为中心, 再根据数据的标准差对数据进行相应的缩放, 使所有数据满足均值为 0, 标准差为 1, 并服从正态分布<sup>[13]</sup>。数据标准化公式为  $X' = (X - u) / \sigma$ 。式中,  $X'$  为标准化后的重型自卸车特征参数,  $X$  为初始特征参数,  $u$  为该特征均值,  $\sigma$  为该特征的标准差。

表 2 数据基本统计表

参数	特征均值	特征标准差	特征最小值	特征上四分位数	特征中位数	特征下四分位数	特征最大值
横摆角速度 / ((°) · s <sup>-1</sup> )	-7.635 525	14.880 898	-31.265 347	-25.232 220	-0.348 442	0.120 477	27.201 625
侧倾角 / (°)	-0.759 934	1.453 790	-3.154 785	-2.402 219	-0.101 812	0.197 958	2.584 934
侧向加速度 / g	-0.211 095	0.447 588	-1.016 897	-0.665 742	-0.017 489	0.003 842	0.797 297
质心侧偏角 / (°)	-0.080 229	2.900 183	-7.172 958	-1.160 902	0.003 586	0.243 744	9.263 137

### 3 车辆侧翻预警模型搭建

#### 3.1 神经网络基本知识

卷积神经网络(Convolutional Neural Networks, CNN)具有和普通神经网络类似的可学习的权重和偏置。CNN 通常是由输入层、卷积层、池化层、全连接层和输出层组成, 其基本结构如图 5 所示。卷积层的




图 5 CNN 神经网络结构图

计算公式为  $F \otimes w = \sum_{k=1}^C \sum_{j=1}^{W_f} \sum_{i=1}^{H_f} (F^k(i, j) w^k(i, j))$ 。

式中:  $\otimes$  表示卷积计算,  $F$  表示输入卷积层的数据,  $w$  表示卷积核的权重参数,  $C, H_f, W_f$  分别为卷积核的通道数、高度、宽度。

LSTM 是基于递归神经网络(Recurrent Neural Network, RNN)的改进模型<sup>[14]</sup>, 其隐藏单元完整逻辑结构如图 6 所示。




图 6 LSTM 神经网络结构图

遗忘门主要负责决定上一时刻从储存单元  $C_{t-1}$  删除多少无用信息, 当前时刻在储存单元  $C_t$  中保留多少有效信息; 输入门主要负责控制导入当前时刻记忆单元  $C_t$  中输入数据  $x_t$  包含多少有效信息; 输出门主要负责控制下一时刻当前记忆单元  $C_t$  将输入多少有效信息给隐藏层。具体计算公式为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), c' = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c),$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), h_t = o_t \cdot \tanh(c).$$

式中,  $f_t$  表示遗忘门,  $i_t$  表示输入门,  $c'$  表示细胞单元,  $o_t$  表示输出门,  $h_t$  表示时步  $t$  时输出,  $W$  表示门的权重,  $\sigma$  表示 sigmoid 函数,  $b$  为门的偏置。

在机器学习应用中,特征提取是一个重要的步骤,将 CNN 和 LSMT 结合起来的意义就在于利用 CNN 中的卷积层来自动提取特征。基于 CNN-LSTM 的重型自卸车侧翻预警模型的基本预测过程为:(1)将预处理好的特征参数输入至 CNN 卷积层,利用卷积核提取特征;(2)提取后的特征从卷积层输入到池化层,降低特征纬度并最大程度保留特征信息;(3)池化层降维处理好的数据输入 LSTM 层进行训练,自动学习车辆侧翻特征;(4)训练误差反向传播机制逐层更新侧翻预警模型的参数;(5)使用 sigmoid 函数将预测结果映射到 $[0,1]$ 作为概率进行输出,完成整个侧翻预警过程<sup>[14]</sup>。CNN-LSTM 神经网络预警模型的结构如图 7 所示。

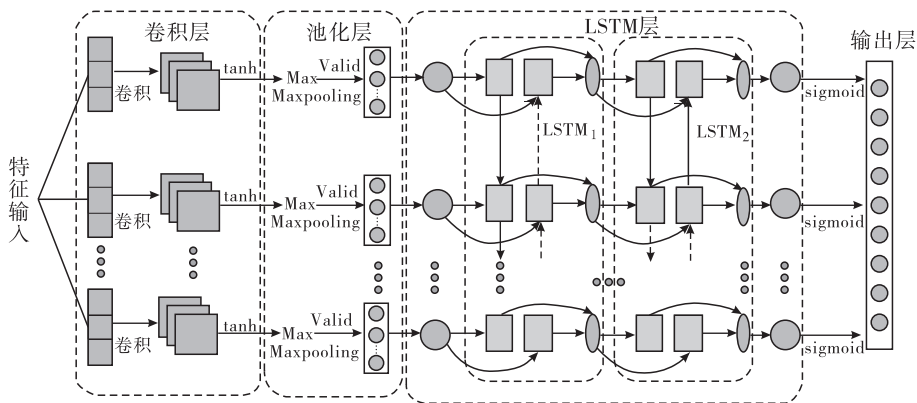


图 7 CNN-LSTM 神经网络预警模型结构图

### 3.2 预警模型搭建

通过文献[15]中的方法以及反复验证调试后,将 CNN-LSTM 神经网络模型具体参数设置如表 3 所示。其中包含:一层一维卷积层作为输入层;一层池化层用于压缩特征,池化层选取最大池,能够在缩减特征维度的同时最大程度的保留所需的特征信息,边界部分填充方式选择全 0 填充;两层 LSTM 网络,主要用来处理特征序列信息;一层 Flatten 层,将从 LSTM 层传入来的多维数据一维化;一层全连接层,用于将特征映射到样本空间;一层 Dropout 层,防止模型过拟合;优化算法选择 adam,损失函数选择二进制交叉熵,以提高计算效率,减少训练时长。

表 3 神经网络模型参数设置

网络层	参数设置	网络层	参数设置
一维卷积层	卷积核数量 128,卷积核大小 3, 步长 1,激活函数 relu,填充方式 same	Flatten 层	默认设置
池化层	池化核大小 1,步长 1,填充方式 same	全连接层	神经元个数 50,激活函数 tanh
LSTM1 层	神经元个数 64,激活函数 tanh	Dropout 层	丢失率 0.2
LSTM2 层	神经元个数 32,激活函数 tanh	输出层	激活函数 sigmoid

### 3.3 结果分析

将处理好的数据划分为测试集和训练集并导入模型中,得到计算结果。为了证明 CNN-LSTM 神经网络在预测重型自卸车问题上具有更好的性能和稳定性,另外搭建了双层 LSTM 模型以及 CNN 模型作为对比。将同样的数据依次输入对比模型,所有模型初始批次大小均设置为 128,迭代次数均为 100,取 5 次迭代均值作为结果。3 种模型的对比输出结果:LSTM 模型准确率(模型对于预测结果的准确程度)为 96.18%,损失值(用于衡量模型预测结果与真实值的差异程度)为 0.0810;CNN 模型准确率为 97.16%,损失值为 0.0599;CNN-LSTM 模型准确率为 98.31%,损失值为 0.0364。测试集的准确率迭代曲线如图

8 所示, 测试集的损失函数迭代曲线如图 9 所示。

由图 8、图 9 可以看出, CNN-LSTM 重型自卸车侧翻预警模型在测试集上对车辆的侧翻平均预测准确率达到 98.31%, 高于其他两种单一神经网络模型对车辆侧翻平均准确率, 且损失值最小, 说明模型的预测值和真实值相差不大, 这证明了该模型与其他模型相比在重型自卸车防翻车预测方面的优越性。




图 8 模型测试集的准确率迭代曲线




图 9 模型测试集的损失函数迭代曲线

### 3.4 模型性能评价

二分类问题常用混淆矩阵<sup>[16]</sup>作为工具来衡量分类模型, 混淆矩阵如表 4 所示。根据混淆矩阵可将样本根据其真实类别与预测类别的组合划分为真正例(TP)、假正例(FP)、真反例(TN)、假反例(FN)<sup>[17]</sup>。由于 sigmoid 函数直接输出的是概率值, 故本文以感受性曲线(receiver operating characteristic curve, ROC)和曲线下面积(Area Under ROC Curve, AUC)来作为模型的性能评估指标。

表 4 混淆矩阵

真实类别	预测结果	
	正例	反例
正例	TP	FP
反例	FN	TN

ROC 经过如下方法得到: 先设置一个阈值, 概率值超过此阈值归类为 0, 概率值低于此阈值则归类为 1, 在阈值从 0 到 1 移动的过程中就会产生很多假正例率和真正例率的值<sup>[18]</sup>。ROC 以假正例率为横坐标, 真正例率为纵坐标, AUC 即为 ROC 与 x 轴所围成的面积。

假正例率、真正例率、曲线下面积的计算方法分别为  $F_{pr} = \frac{F_p}{F_p + T_p}$ ,  $T_{pr} = \frac{T_p}{T_p + F_n}$ ,  $A_{uc} = \int R_{\alpha}$ 。式中,  $F_{pr}$  为假正例率,  $F_p$  为假正例值,  $T_p$  为真正例值,  $T_{pr}$  为真正例率,  $F_n$  为假反例值,  $A_{uc}$  为曲线下面积,  $R_{\alpha}$  为感受性曲线函数。

图 10(a)~(c) 分别为 CNN 预警模型的 ROC、LSTM 预警模型的 ROC、CNN-LSTM 预警模型的 ROC。图中 ROC 与 x 轴围成的面积, 即为  $A_{uc}$  的值。




图 10 3 种预警模型的 ROC

由图 10 可知, CNN 预警模型的  $A_{uc}$  值为 0.996; LSTM 预警模型的  $A_{uc}$  值为 0.995; CNN-LSTM 预警

模型的  $A_{uc}$  值为 0.999, CNN-LSTM 预警模型的  $A_{uc}$  值最大, 表明其性能在 3 种模型中最优, 结合 3.3 小节的结果分析可得出结论: 利用 CNN-LSTM 神经网络搭建的重型自卸车侧翻预警模型的性能优于仅仅使用单一神经网络搭建的预警模型, 且该模型性能可靠, 预测准确度高。

#### 4 结论

经上述验证, 可得到以下主要结论。(1) 本文利用 MATLAB/Simulink 与 Trucksim 联合仿真搭建重型自卸车仿真模型, 用 CNN-LSTM 神经网络搭建重型自卸车侧翻预警模型, 模型对车辆侧翻预测准确率为 98.31%, 曲线下面积值为 0.999, 表明该模型对重型自卸车的侧翻预警具有较高的准确率和可靠性。(2) 本文另外搭建了基于 CNN、LSTM 神经网络的重型自卸车侧翻预警模型作为对比, 两种模型的预测正确率分别为 97.16%、96.18%, 曲线下面积值分别为 0.996、0.995, 两项数据均低于基于 CNN-LSTM 搭建的重型自卸车侧翻预警模型, 表明本文所提出的基于 CNN-LSTM 搭建的重型自卸车侧翻预警模型相较于其他两种基于单一神经网络搭建的重型自卸车侧翻预警模型具有更高的优越性。

虽然本文较为全面的验证了 CNN-LSTM 侧翻预警模型的可靠性, 但仍有以下两点值得后续深入研究。(1) 本文的模型训练数据是基于重型自卸车仿真模型提取而来的, 模型侧翻预警功能主要针对重型自卸车, 然而在实际生活中 SUV 等质心较高的车辆也易发生侧翻, 后续研究可在模型训练数据中加入其他车型的运行特征, 从而提高模型的泛化性。(2) 本文在搭建侧翻预警模型时只考虑了重型自卸车的 4 种运行参数, 后续研究亦可增加新的影响车辆稳定性的参数, 如司机驾驶行为等来提高模型预测精度和模型泛化性。

#### 参考文献:

- [1] 靳亚格. 基于 DEMATEL-ISM 的高速公路交通事故影响因素研究[D]. 西安: 长安大学, 2022.
- [2] HOU J, LEI H, FU Z, et al. A novel rollover warning approach for commercial vehicles using unscented Kalman filter[J]. Mathematical problems in engineering, 2022, 2022: 1-13.
- [3] MIYAMOTO S, OYA M. Improved rollover prevention controller for heavy vehicles with varying velocity and values of vehicle parameters[J]. Artificial life and robotics, 2022, 27(3): 521-527.
- [4] 于志新, 宗长富, 何磊, 等. 基于 TTR 预警的重型车辆防侧翻控制算法[J]. 吉林大学学报(工学版), 2009, 39(S2): 251-254.
- [5] 李胜琴, 杜鹏, 冯新园. 微型客车防侧翻底盘集成控制策略[J]. 江苏大学学报(自然科学版), 2022, 43(2): 131-138.
- [6] 康小鹏, 董浩, 祁传琦, 等. 利用车辆状态估计的客车防侧翻控制[J]. 机械设计与制造, 2022(7): 10-13.
- [7] LU Y, HAN Y, HUANG W, et al. Sliding mode control for overturning prevention and hardware-in-loop experiment of heavy-duty vehicles based on dynamical load transfer ratio prediction[J]. Proceedings of the institution of mechanical engineers, part K: journal of multi-body dynamics, 2022, 236(1): 68-83.
- [8] 姚嘉凌, 李智宏, 田松梅, 等. HMM 与神经网络相结合的车辆侧翻预警研究[J]. 机械设计与制造, 2017(11): 178-182.
- [9] JIN Z, LI J, HUANG Y, et al. Study on rollover index and stability for a triaxle bus[J]. Chinese journal of mechanical engineering, 2019, 32: 1-15.
- [10] 陈东乐. 重型车辆侧翻因素探讨[J]. 汽车实用技术, 2016(2): 144-145.
- [11] 廖聪, 吴新辉, 黄红武. 客车半主动悬架防侧翻模糊滑模控制[J]. 厦门大学学报(自然科学版),

- 2014,53(3):373-377.
- [12] 廖子文,宫爱红,胡明茂,等.考虑货箱质心变化的重型自卸车举升侧翻分析[J].湖北汽车工业学院学报,2019,33(4):20-24.
- [13] 杨丽丽,田伟泽,徐媛媛,等.谷物联合收割机油耗随机森林预测模型[J].农业工程学报,2021,37(9):275-281.
- [14] 樊家伟,郭瑜,伍星,等.基于 LSTM 神经网络和故障特征增强的行星齿轮箱故障诊断[J].振动与冲击,2021,40(20):271-277.
- [15] 邢红涛,郭江龙,刘书安,等.基于 CNN-LSTM 混合神经网络模型的  $\text{NO}_x$  排放预测[J].电子测量技术,2022,45(2):98-103.
- [16] 王同,许昕,潘宏侠.基于多域信息融合与深度分离卷积的轴承故障诊断网络模型[J].机电工程,2024,41(1):22-32.
- [17] 徐展良.基于高斯相互作用属性核相似性的长非编码 RNA 与环境因素关联关系预测研究[D].广州:华南理工大学,2018.
- [18] 李婷.基于时序 CNN 与稀疏光流的监控视频人车异常检测方法[D].武汉:武汉理工大学,2019.

## Rollover Warning Study of Heavy Dump Truck Based on CNN-LSTM

WANG Jiaming, HU Mingmao, SHI Guodong, ZHU Tianmin

(School of Mechanical Engineering, Hubei Institute of Automotive Technology,  
Shiyan 442000, China)

**Abstract:** In order to solve the rollover warning problem of heavy dump truck, based on the CNN-LSTM neural network, a rollover early warning model for heavy-duty dump trucks is constructed to achieve real-time determination under different working conditions. Using Trucksim and MATLAB/Simulink joint simulation, a heavy dump truck simulation model is built. With the lateral load transfer rate equal to  $\pm 0.85$  as the rollover threshold, the vehicle operating parameters under different working conditions are extracted and the vehicle operating parameters are used. The CNN-LSTM heavy-duty dump truck rollover early warning model is trained and compared with the early warning models based on CNN and LSTM respectively. The results show that the prediction accuracy of CNN-LSTM heavy dump truck rollover warning model is 98.31%, and the area under ROC curve is 0.999, which is higher than the rollover warning model built by a single neural network. It is clear that the CNN-LSTM heavy dump truck rollover warning model has some advance warning significance and is useful for reducing the occurrence of heavy dump truck rollover accidents.

**Keywords:** heavy dump truck; CNN-LSTM neural network; lateral load transfer rate; rollover warning model; simulation

(责任编辑:王新亮)