

DOI:10.19344/j.cnki.issn1671-5276.2024.02.010

# 基于 GAN-GRU 的电梯制动力矩预测方法

苏万斌<sup>1</sup>, 江叶峰<sup>1</sup>, 易灿灿<sup>2</sup>, 徐彪<sup>2</sup>

(1. 嘉兴市特种设备检验检测院, 浙江 嘉兴 314050; 2. 武汉科技大学, 湖北 武汉 430081)

**摘要:** 电梯制动器的制动力矩是影响电梯运行安全的关键参数, 利用深度学习算法对其进行预测, 能为电梯的安全使用和后期维保提供重要参考。基于门控神经网络(GRU)预测模型, 结合生成对抗网络(GAN)的基本思想, 以 1D-CNN 作为鉴别器, 提高电梯制动力矩预测模型的泛化能力。利用实验数据进行训练, 获得的预测结果方均根误差为 1.024 4, 并与常用的时间序列分析模型如 GRU、LSTM 等进行对比, 结果表明: 所提出的方法在电梯的制动力矩预测精度上具有明显的优势。

**关键词:** 电梯; 制动力矩; 时间序列分析; 生成对抗网络; 门控循环神经网络

**中图分类号:** TH17 **文献标志码:** A **文章编号:** 1671-5276(2024)02-0050-06

## Prediction Method of Elevator Braking Torque Based on GAN-GRU

SU Wanbin<sup>1</sup>, JIANG Yefeng<sup>1</sup>, YI Cancan<sup>2</sup>, XU Biao<sup>2</sup>

(1. Jiaxing Special Equipment Inspection and Testing Institute, Jiaxing 314050, China;

2. Wuhan University of Science and Technology, Wuhan 430081, China)

**Abstract:** The braking torque of elevator brake is a key parameter affecting the safety of elevator operation. Deep learning algorithm is used to predict it, which can provide an important reference for the safe use and subsequent maintenance of the elevator. Based on the Gated Neural Network (GRU) prediction model, this paper combines it with the basic idea of Generative Adversarial Network (GAN), and uses 1D-CNN as the discriminator to enhance the generalization ability of the elevator braking torque prediction model. The experiment data is applied for training to obtain the prediction result with the root mean square error indicating as 1.024 4. Comparison is conducted with commonly used time series analysis models such as GRU and LSTM, and the results show that the proposed method has obvious advantages in the prediction accuracy of elevator braking torque.

**Keywords:** elevator; braking torque; time series analysis; generate adversarial network; gated recurrent neural networks

## 0 引言

电梯已被广泛安装在如大型工厂、政府机关、居民小区、商场等场合。截至 2021 年底, 全国电梯保有量达到 879.98 万台, 其中老旧电梯约占总数的 5%, 3 年后, 将增至 8%, 其中使用鼓式制动器的低速电梯仍为主流<sup>[1]</sup>。制动器作为电梯最重要的安全部件, 其可靠性至关重要。制动器性能的重要指标是制动力矩, 当制动力矩不足时, 制动器难以对电梯进行有效制停, 极易导致严重的人员伤亡与财产损失<sup>[2]</sup>。2010 年至 2021 年, 全国因制动力矩不足造成的电梯事故超过 18 起, 造成的人员伤亡超过 27 人。例如, 2021 年 5 月 23 日, 广东湛江市某小区内, 因制动器故障导致电梯发生冲顶, 造成一人死亡, 其原因在于电梯的制动力

矩随电梯的使用时间而逐渐降低, 最终无法满足电梯的制动安全要求<sup>[3]</sup>。

现有关于制动器力矩的研究主要在如何有效、准确地检测出制动力矩, 主流方法为在制动状态下对制动器施加转矩, 直至制动轮刚好发生滑动, 测出当前的力矩定义为最大静载荷旋转力矩, 即所测制动器的最大制动力矩<sup>[4]</sup>。这种方式能直观有效地检测出电梯的实际力矩, 但也不可避免地对电梯的制动性能产生负面影响。鼓式制动器的制动轮与制动闸瓦产生相对滑动, 会对制动闸瓦造成极大的消耗, 降低制动器的制动性能<sup>[5]</sup>。综上, 尽管电梯制动器的制动力矩是电梯安全评估的重要参考指标, 但在实际的检测维护中很难对其进行趋势预测。因此, 如何有效检测电梯的制动力矩并对其退化状况进行预测, 从而避免制

**基金项目:** 国家自然科学基金项目(U1709210, 51805382); 2019 年浙江省省级市场监管科研计划项目(20190339); 2020 年浙江省市场监管局质量技术基础建设项目(20200126)

**第一作者简介:** 苏万斌(1972—), 男, 浙江嘉兴人, 高级工程师, 本科, 研究方向为特种设备检验检测技术, swb197212138@163.com。

动器故障导致的事故发生是当下研究的热点。目前,梁庆海等基于 Gamma 过程实现了制动器磨损退化预测<sup>[6]</sup>;季景方等利用回归分析实现盘式制动器制动温度预测<sup>[7]</sup>。以上研究表明针对制动器进行时序预测以提高安全性是可以实现的。

当前的时序预测方法中,如支持向量回归(support vector regression, SVR)等传统机器学习方法能拟合数据间的非线性关系,但难以考虑多因素的影响,面对复杂度较高的电梯制动性能退化问题时效果较差<sup>[8]</sup>。回声状态网络(echo state network, ESN)具有很快的运行速度,可以进行高效的预测,然而预测精度较低,同时在小样本上效果不佳<sup>[9]</sup>。电梯制动力矩的数据采集问题导致无法获取大量数据,采样间隔大,因此不适宜用 ESN 进行预测。循环神经网络(recurrent neural network, RNN)是用于处理时序问题的深度神经网络,在时序问题如交通流预测上取得了较好的效果,其改进模型门控神经网络(gated recurrent unit, GRU)通过门系统建立数据前后端联系,通过很少的计算量提升了模型性能,具有优秀的数据挖掘能力<sup>[10-11]</sup>。然而,作为递归神经网络的一种,进行序列预测时,较早预测数据的误差会对后续的预测产生干扰,影响预测的精度。神经网络的梯度反向传播特性可以在训练时提高模型的精度,增强模型性能,但在预测时却无法实现<sup>[12]</sup>。而生成对抗网络(generative adversarial networks, GAN)具有类似的思路,即通过生成器产生结果,鉴别器进行判断,双方对抗以达到纳什均衡,从而使生成器与鉴别器都获得最佳性能<sup>[13]</sup>。在时序预测任务上,同样可以利用生成对抗网络的思路,加入强大的鉴别器以对模型预测进行监督,提升预测精度。

考虑到电梯制动力矩时序预测的特性,由于其运行、制动状况存在极大的随机性,受人为因素干扰严重,很难直接捕捉数据间的时序信息。针对使用越来越广泛的民用低速电梯,为实现全方位精确地预测电梯制动力矩,本文提出了基于 GAN-GRU 的电梯制动力矩预测方法。首先采集电梯制动实验下的制动平均减速度、制动距离、运行总距离及制动力矩以反映电梯实际的运行状态,之后利用 GRU 对制动力矩进行多因素的时间序列预测,最后结合 GAN 生成对抗思路,使用 CNN 对预测结果进行精确度判别以解决时序模型的预测误差累积问题。本文使用电梯制动性能试验机采集具有不同运行状态的制动器数据,在

进行归一化后利用多种算法对制动力矩进行预测,验证了本文所提出模型的准确性,为提高电梯的使用安全提供了新的技术手段。

## 1 理论与算法

### 1.1 GRU 网络模型

门控神经网络 GRU 是基于 LSTM 的一种改进循环神经网络模型。其将 LSTM 模型中的门系统整合为一个,极大简化了计算量并提高了模型性能。数据的特征储存在隐藏状态中经过门系统不断更新,实现对序列数据的学习<sup>[14]</sup>。

GRU 神经元的结构如图 1 所示,其利用更新门与重置门结构处理时序信息,二者均由 sigmoid 函数构成。通过函数对前记忆状态信息与当前输入的数据进行函数变换,实现数据信息筛选。相对于传统 LSTM,其主要发展在于将 LSTM 中的遗忘门和输出门整合为一个更新门限  $Z_t$ ,并将 LSTM 中的网络记忆合并至隐藏状态中输出。因此使得 GRU 模型具有更少的参数,降低了计算量,减缓了过拟合的问题,提高了模型性能。

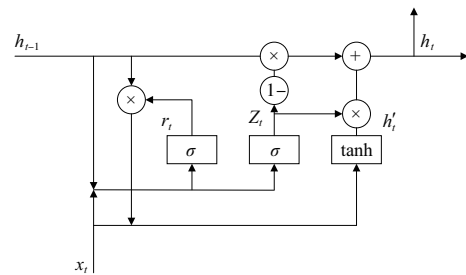


图 1 GRU 神经元结构

如图 1 所示, $t$  时刻 GRU 神经元状态的中间变量计算公式为:

$$Z_t = \text{sigmoid}(W_z[h_{t-1}, X_t]) \quad (1)$$

$$r_t = \text{sigmoid}(W_r[h_{t-1}, X_t]) \quad (2)$$

$$h'_t = \text{sigmoid}(W \cdot [r_t \cdot h_{t-1}, X_t]) \quad (3)$$

式中: $Z_t$  表示更新门控, $r_t$  表示重置门控,二者均取值 0~1,共同组成 GRU 的门系统; $h'_t$  表示包含当前输入信息的中间变量; $h_{t-1}$  表示上一时刻的隐藏状态输出; $X_t$  表示当前状态输入; $W$  表示可训练的权值矩阵。神经元输出为

$$h_t = (1 - Z_t) \cdot h_{t-1} + Z_t \cdot h'_t \quad (4)$$

GRU 模型中重置门控制保存上一神经元输出数据特征的权值,更新门控制当前神经元输入数据信息的权值,中间权值通过训练集训练更新并在训练完成后保存,形成预测模型。

### 1.2 CNN 网络模型

卷积神经网络是可靠的分类器,在图像与信号的分类上都有很好的效果。一维卷积神经网络(1D-CNN)利用卷积核与序列信号进行运算,通过全连接分类器进行分类,可以实现高效可靠的分类<sup>[15]</sup>。CNN 与传统神经网络相比,通过卷积核权值共享极大降低了计算量,同时卷积核可以提取高维特征,对数据进行更细致的区分。卷积神经网络结构如图 2 所示。




图 2 1D-CNN 网络结构

1) 池化层:对特征进行降采样,筛选出更优价值的信息同时减少计算量。

2) 卷积层:通过卷积计算进行特征的提取,本文使用带有 3 层卷积的模型进行特征提取,结合池化使最终输出能包含输入序列的全部特征。

3) 全连接层:用于整合提取的特征信息并进行分类,输出预测结果的可靠性判断。

输入的分布特征向量按照下式计算。

$$h_i^k = f_a [(W_k \cdot d')_i + b_k] \quad (5)$$

式中: $h_i^k$  是指第  $i$  个分布特征向量在第  $k$  层进行卷积运算后的值; $f_a$  是激活函数; $W_k$  是该层的权重值; $b_k$  是对应的偏置值。

卷积神经网络 CNN 对 GRU 的预测数据进行判断,当置信度较低时,可返回生成器重新生成,以此监督生成器预测,缓解预测误差累积,提高预测精度。

### 1.3 基于 GAN 的电梯制动力矩预测模型

针对时间序列预测模型存在预测误差累积的问题,提出结合生成对抗网络(GAN)思想的 GRU 预测模型。GAN 由生成器 G 和鉴别器 D 在对抗过程中同时训练。首先,从已知概率分布中采样噪声向量  $Z$ 。G 将噪声向量  $Z$  作为输入,并进行训练以生成分布遵循原数据的样本<sup>[16]</sup>。另一方面,D 被优化以区分生成的数据和真实数据。本研究以 GRU 预测模型作为生成器,通过不断预测生成不同的预测结果,将预测错误的序列信息作为负样本,预测正确的作为正样本,将所有样本对 CNN 进行训练并判别是否属于正确预测结果曲线,具体如图 3 所示。

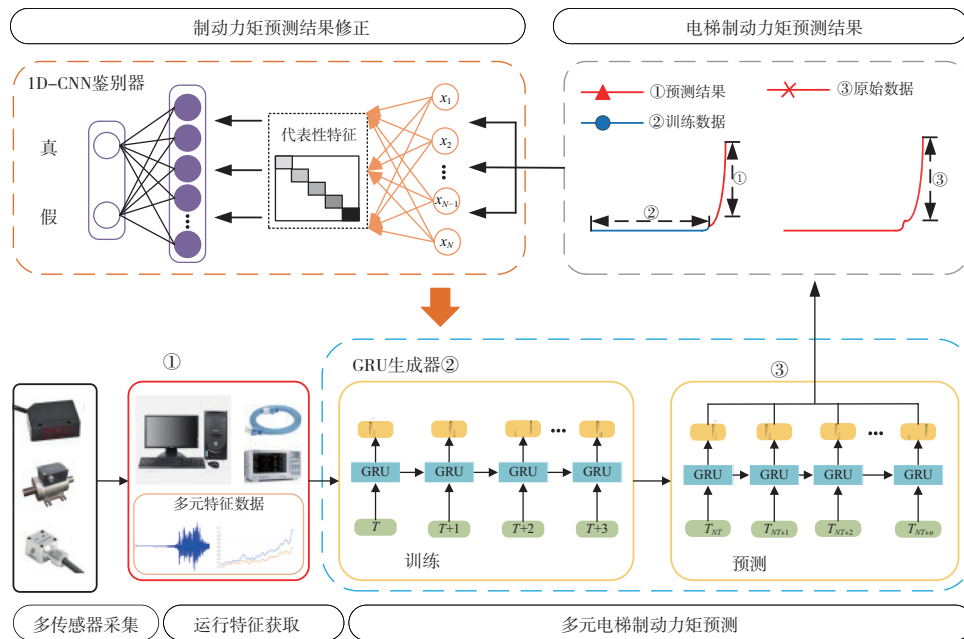


图 3 GAN-GRU 模型结构图

如图 3 所示,GRU 通过训练集  $T$  生成预测序列  $\tilde{P}$ ,以此作为生成器用来生成预测数据曲线,

1D-CNN网络则对 GRU 提供的  $\tilde{P}$  生成相应的置信度标签  $D(\tilde{P}) \in [0,1], D(\tilde{P}) \in [0,1]$  意味着  $\tilde{P}$  符

合预测要求,即当训练集  $T$  已知时,预测集  $P$  的条件概率应该如下定义:

$$p(P|T) = p(x_{m+1}, \dots, x_n | x_1, \dots, x_m) = \prod_{i=1}^{n-m} p(x_i | T, x_{m+1}, \dots, x_{i+m}) \quad (6)$$

为了最小化预测误差叠加问题,考虑到权重、偏置等内部参数的影响,利用上述条件概率来获得最优的参数,采用以下公式:

$$\theta^* = \operatorname{argmax} \sum_{i=1}^{n-m} \log p(x_i | T, x_{m+1}, \dots, x_{i+m}; \theta) \quad (7)$$

式中  $\theta$  代表模型的所有内部参数。

对于 1D-CNN 来说,目的是在对抗训练中判断  $\tilde{P}$  是来自真实的数据还是生成模型 GRU,直到无法判断真假,此时 GRU 则能生成出最符合真实数据分布的预测曲线,1D-CNN 作为鉴别器,其目标函数可以化为如下所示的损失:

$$L_D(y, D(\tilde{P})) = -\frac{1}{m} \sum_{i=1}^m [(y^{(i)} \log(D(\tilde{P}_i)) + (1 - (y^{(i)})^* \log(1 - D(\tilde{P}_i)))] \quad (8)$$

式中:  $m$  表示输入序列中的样本数;  $y^{(i)}$  和  $D(\tilde{P}_i)$  分别表示真实标签和判别标签。训练的最终目标是最大限度地减少对数似然,如下式:

$$\min \operatorname{imizing}: L(P|T) = E_{x \sim P(P)} [\log p(P|T)] + E_{x \sim P(T)} [\log(1 - D(G(P)))] \quad (9)$$

式中:  $E$  表示数学期望;  $G(P)$ 、 $D(G(P))$  分别为生成器的生成序列与鉴别器的判别概率。

$L(P|T)$  的值越小则说明生成器生成的预测数据更真实,置信度更高,更符合要求,否则鉴别器会让生成器返回修改,并进一步降低  $L(P|T)$  的值,最后满足纳什均衡。

## 2 实例分析

### 2.1 数据来源

本文数据通过实验室环境下搭建的实验平台采集获得。实验台由控制系统、台架、加载电机、制动器及速度和距离等传感器组成,如图 4 所示。由加载电梯模拟电梯轿厢运行而产生的转矩力,经过减速传感器模拟电梯轿厢的运行速度,通过制动器抱闸制停并以转矩转速传感器等测量制动器的制动力矩与制动距离。利用速度传感器记录实验模拟的运行速率、制动平均减速度等,距离传感器记录制动器的闸瓦间隙。整个实验过程按 GB/T24478—2009《电梯曳引机》和 TSGT7007—

2016《电梯型式试验规则》标准进行。



图 4 电梯制动性能测试实验台

在电梯的运行过程中,闸瓦片与制动轮通过摩擦制动,往往会产生较大的摩擦磨损。磨损及结构松动产生的闸瓦间隙变化是电梯制动器结构中变化最大的部分。间隙增大会导致压力角变化,也会增加电梯的制动时间,是影响制动器性能的关键参数。为了更好地观察制动力矩在制动器退化过程中的变化,实验通过调整制动闸瓦间隙模拟电梯使用中的闸瓦磨损,间隙从 0.2 mm 递增调整至 1.8 mm,每次增加 0.2 mm。随着间隙增大,闸瓦受到的摩擦损伤同样增加,从而模拟现实中电梯闸瓦片厚度与表面摩擦状态的损失情况。考虑到实际电梯维护中难以进行大量实验测量,在实验机上进行 45 次实验,利用转矩转速传感器、速度传感器、距离传感器等采集获得实验条件下制动的制动力矩、平均减速度、制停距离、运行总距离等参数。其中制动力矩是电梯安全评估的关键参数,也是本文需要预测的目标;制动间隙是影响制动力矩的一大因素;制动距离、平均减速度是随制动力矩变化而变化的参数;运行距离是实验条件,与实验时电机的速率等参数相关。部分数据如表 1 所示,使用其中前 40 组作为训练集,后 5 组作为测试集,分别使用 GAN-GRU、GRU、LSTM、ESN 算法对数据进行分析预测,以验证本文所提出的模型在电梯制动力矩预测上的优势。

表 1 实验采集制动器部分数据

制动间隙/mm	平均减速度/(m/s)	制动距离/m	运行距离/m	制动力矩/N·m
0.2	3.57	4.893	41.786	1 288.2
0.4	3.54	4.876	49.875	1 248.6
0.6	3.65	4.872	41.026	1 284.3
0.8	3.52	4.876	49.884	1 248.6
1.0	3.58	4.773	49.818	1 242.1

## 2.2 模型预测

设定GAN中生成器GRU的参数为:学习率0.000 1,训练次数100,神经元个数100。设定GAN中鉴别器1D-CNN的参数为3层卷积层,2层池化层,使用Relu作为激活函数,使用 $3 \times 3$ 尺寸卷积核,输出使用Softmax进行二分类。同时,利用预测结果的方均根误差RMSE与平均绝对百分误差MAPE量化模型预测精确度。本文分别利用GAN-GRU与原始GRU进行预测,所使用GRU的参数一致,其预测结果如图5所示,计算得GAN-GRU模型的RMSE值为1.024 4,MAPE值为0.054 7。相对于原始GRU模型的RMSE值为1.561 5,MAPE值为0.131 5,使用CNN作为鉴别器的GAN-GRU模型具有近30%预测精度的提升。




图5 GAN-GRU与GRU预测结果的比较

由图5也可以看出,本文提出的方法在针对电梯制动力矩进行多步时间预测时,具有很好的预测效果。在误差出现后也能对后续的数据产生不错的预测结果,预测结果与实际结果几乎一致,证明结合GAN生成对抗思路的预测模型在电梯时序数据预测上具有一定的优势。

为了验证模型的优越性,使用LSTM与ESN构建预测模型进行横向对比,如图6所示。LSTM使用参数同上文实验中的GRU参数。ESN设定储备池数量为300,稀疏度为5%,储备池谱半径设为0.8,计算得到的预测结果如图6(b)所示。




图6 LSTM与ESN预测结果的比较

由图6可知,相对于回声状态网络预测模型,

LSTM的预测结果更好,主要在于初始预测时存在一定误差,影响后续预测效果,而ESN网络对电梯制动力矩的预测效果更差,可信度更低。为更直观对比各模型的预测效果,分别计算各模型的方均根误差RMSE与平均绝对百分误差MAPE,如表2所示。由表2可以看出,本文提出的GAN-GRU模型具有更好的预测精度和模型泛化能力,可以用于电梯制动力矩数据的预测分析。

表2 不同模型预测结果评价指标对比

预测模型	$R_{MSE}$	$M_{APE}$
GAN-GRU	1.024 4	0.054 7
GRU	1.561 5	0.131 5
LSTM	1.978 1	0.142 8
ESN	3.360 4	0.246 0

## 3 结语

针对曳引式电梯制动力矩退化影响电梯安全而难以进行诊断与预警这一问题,本文在门控神经网络GRU的基础上,结合生成对抗网络GAN的思路,利用GRU作为生成器生成预测结果,再利用卷积神经网络CNN作为鉴别器进行结果可靠性判断,迭代训练提高最终预测结果的精度。GAN-GRU具有更良好的预测效果,生成对抗学习的思路有利于缓解时间序列多步误差中的误差累积问题,CNN针对数据整体进行可靠性判断,因此即使出现误差,模型依然可以对后续的预测进行校正,因而整体预测精度更高。

本文利用自制的电梯制动性能实验平台获取原始数据,通过模拟现场环境,改变闸瓦间隙获取45组数据,并分别利用GAN-GRU、原始GRU、LSTM、ESN网络模型对数据进行学习预测。结果表明:在电梯的制动力矩预测任务上,GAN生成对抗思路能提升GRU的预测效果接近30%,预测精确度相较于最常用的长短期记忆网络LSTM高出近50%。这表明本文所提出的模型在电梯制动器的力矩预测上具有一定的优势,可以为电梯的检测与维护提供参考。

## 参考文献:

- [1] 叶伟. 基于AHP和熵权法的电梯安全综合评价[J]. 标准科学, 2022(6): 112-116.
- [2] 陈向俊,傅军平,陈栋栋,等. 基于极端梯度提升回归模型的电梯钢丝绳磨损预测方法[J]. 机电工程, 2022, 39(4): 554-560.

- [3] 苏万斌,江叶锋,陈启锐,等. 基于Abaqus的电梯制动器制动轮热应力分析[J]. 新技术新工艺, 2021, 404(8):43-48.
- [4] 邓林,吴晓军. 电梯制动器温度与制动力的影响因素分析[J]. 起重运输机械, 2020(9):51-54.
- [5] 郝家琦,徐金海,鲍超超,等. 基于VMD与SVM的电梯鼓式制动器故障诊断研究[J]. 机电工程, 2022, 39(1):112-119.
- [6] 梁庆海,贾希胜,白云杰. 基于Gamma过程的制动器磨损退化建模与剩余寿命预测[J]. 公路与汽运, 2021(5):1-5.
- [7] 季景方,张建辉,范佳能,等. 基于回归分析理论的盘式制动器制动温度预测研究[J]. 汽车实用技术, 2019(18):75-77.
- [8] 顾昕雨,肖志刚. ARIMA-SVR组合模型在卫星遥测参数预测中的应用[J]. 空间科学学报, 2022, 42(2):306-312.
- [9] 琚垚,祁林,刘帅. 基于改进乌鸦算法和ESN神经网络的短期风电功率预测[J]. 电力系统保护与控制, 2019, 47(4):58-64.
- [10] 孟海宁,童新宇,石月开,等. 基于ARIMA-RNN组合模型的云服务器老化预测方法[J]. 通信学报, 2021, 42(1):163-171.
- [11] 杨芮,徐虹,文武. 基于EEMD-GRU网络模型的短期风速预测[J]. 计算机系统应用, 2022, 31(6):231-237.
- [12] 窦勇敢,袁晓彤. 基于隐式随机梯度下降优化的联邦学习[J]. 智能系统学报, 2022, 17(3):488-495.
- [13] 徐硕,侯贵生. 基于VAE-D2GAN的涡扇发动机剩余使用寿命预测[J]. 计算机集成制造系统, 2022, 28(2):417-425.
- [14] 张忠林,张艳. 改进FA优化LSTM的时序预测模型[J]. 计算机工程与应用, 2022, 58(11):125-132.
- [15] 陈可嘉,刘惠. 基于改进BiGRU-CNN的中文文本分类方法[J]. 计算机工程, 2022, 48(5):59-66, 73.
- [16] 江涛,刘鑫容,朱耀琴,等. 基于GAN-CNN联合网络的复杂产品费用预测[J]. 电子设计工程, 2020, 28(17):174-179, 184.

收稿日期:2022-09-09

(上接第28页)

是3个,只是大小和位置的不同,3种敞车两侧的压力分布非常相似,这是3种类型列车侧向力都非常接近的原因。

### 3 结语

本文针对不同装载情况下的敞车,开展了敞车在空载、半载、满载3种情况下气动性能的研究。采用SIMPLE算法求解雷诺平均N-S方程,湍流模型采用SST  $k-\omega$  模型。研究结果表明:空载敞车所受的气动阻力最大,半载敞车次之,满载敞车所受的气动阻力最小;满载敞车所受的气动升力最大,半载敞车次之,空载敞车最小;3种敞车所受的侧向力非常接近,最大差距仅为1.9%;对于同一种车型而言,每节车所受的气动力也有所不同;单节敞车气动力的变化规律与整车气动力的变化规律一致,空载敞车和半载敞车所受的气动力较为接近,而满载敞车所受的气动力与前2种车型有明显差距。此研究结果可为货运列车的安全运行提供参考。

### 参考文献:

- [1] 梁习锋,熊小慧. 4种车型横向气动性能分析与比较[J]. 中南大学学报(自然科学版), 2006, 37(3):607-612.
- [2] 周丹,田红旗,杨明智,等. 强侧风作用下不同类型铁

路货车在青藏线路堤上运行时的气动性能比较[J]. 铁道学报, 2007, 29(5):32-36.

- [3] 何华,田红旗,熊小慧,等. 横风作用下敞车的气动性能研究[J]. 中国铁道科学, 2006, 27(3):73-78.
- [4] 金琦,梁习锋,熊小慧. 横风对篷布气动升力的影响[J]. 铁道科学与工程学报, 2010, 7(4):96-100.
- [5] 熊小慧,梁习锋,金琦. 横风作用下铁路货车篷布气动力数值模拟计算[J]. 中南大学学报(自然科学版), 2015, 46(2):728-735.
- [6] HASSAN H, CHRIS B. Large-eddy simulation of the flow around a freight wagon subjected to a crosswind[J]. Computers & Fluids, 2010, 39(10):1944-1956.
- [7] 赵怀瑞. 车辆工程导论[M]. 北京:中国铁道出版社, 2015.
- [8] 李田,秦登,安超,等. 计算网格对列车空气动力学不确定性的影响[J]. 西南交通大学学报, 2019, 54(4):816-822.
- [9] PREMOLI A, ROCCHI D, SCHITO P, et al. Comparison between steady and moving railway vehicles subjected to crosswind by CFD analysis [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2016, 156:29-40.
- [10] TB/T 3503.4—2018 铁路应用空气动力学 第4部分:列车空气动力学性能数值仿真规范[S].

收稿日期:2022-10-10