

DOI:10.19651/j.cnki.emt.2108382

基于数据不平衡下的高速列车小幅蛇行预测方法^{*}

宁云志 宁静 李艳萍 陈春俊

(西南交通大学机械工程学院 成都 610031)

摘要: 高速列车行驶中所产生的蛇行运动会严重影响到列车的行驶安全,所以对蛇行运动进行预测可以做到提前预警。目前对于蛇行运动的研究主要为对蛇行失稳的预测,但列车运行过程中会出现正常到蛇行失稳的小幅蛇行中间状态,对小幅蛇行状态进行预测可以提前对蛇行失稳进行预警。为此,以高速列车转向架横向加速度信号为标准,针对高速列车蛇行运动数据的极端不平衡情形,提出了一种基于1D-CNN和CGAN的非平衡数据的预测方法。该方法首先利用CGAN的对抗性学习机制,通过生成器和鉴别器之间的博弈来优化更新参数。然后,将训练完备的CGAN模型用于生成样本,将增强后的数据送入1D-CNN分类器,并输出预测结果。在高速列车实际运行数据上进行实验,结果表明CGAN可以拟合高速列车蛇行故障运动的数据分布并增强数据集,且基于提出的方法预测精度为97.5%,大幅优于对比方法。因此基于CGAN-1DCNN的小幅蛇行预测方法可以在数据不平衡下对小幅蛇行的预测,实现对蛇行失稳的提前预警。

关键词: 高速列车;小幅蛇行;生成式对抗网络;卷积神经网络

中图分类号: U216.3; TH17; TN98 文献标识码: A 国家标准学科分类代码: 460.4030

High-speed train small-amplitude hunting prediction method based on data imbalance

Ning Yunzhi Ning Jing Li Yanping Chen Chunjun

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: The hunting motion generated by high-speed trains can seriously affect the safety of trains, so predicting hunting motion can provide early warning. The current research on hunting motion is mainly about the prediction of hunting instability, but there is a small-amplitude hunting intermediate state between normal and hunting instability during train operation, and the prediction of the small-amplitude hunting state can provide early warning of hunting instability. To this end, a prediction method for imbalanced data based on a one-dimensional convolutional neural network 1D-CNN and a conditional generative adversarial network CGAN is proposed for the extreme imbalanced case of high-speed train hunting motion data using the bogie lateral acceleration signal as the standard. The adversarial learning mechanism of CGAN method first utilised to optimise the update parameters through a game between the generator and the discriminator. The well-trained CGAN model is then used to generate samples, feed the enhanced data into a 1D-CNN classifier, and output the prediction results. Experiments are conducted on actual high-speed train operation data, and the results show that CGAN can fit the data distribution of high-speed train hunting fault motion and enhance the dataset, and the prediction accuracy based on the proposed method is 97.5%, which is substantially better than the comparison method. Thus the CGAN-1DCNN-based minor hunting prediction method can predict minor hunting under data imbalance and achieve early warning of hunting instability.

Keywords: high-speed trains; small-amplitude hunting; GAN; CNN

0 引言

在中国,高速列车的发展正处于新兴阶段,几乎所有的

列车和轨道系统都是在2008年以后新修建的,目前尚未到达故障的集中爆发期。由于蛇行运动对高速列车的安全具有极大威胁,因此在列车产生明显的蛇行运动以前,系统将

收稿日期:2021-11-17

*基金项目:国家自然科学基金(51975486,51975487)项目资助

通过减速等相关运动阻止蛇行运动的产生。因此,以上两点导致现有的监测数据中大量存在的是正常数据,出现故障的数据是少之又少,从而导致获得的观测数据具有极端的类别不平衡特点,这一现象使得通过运用机器学习的方法对蛇行故障进行精确识别带来了很大困难。

由于列车的轮对具有一定锥度,造成轮对产生绕着其运行轨道的中心线一边横移一边摇头的耦合运动,即蛇行运动^[1]。当列车速度超过临界值时,列车蛇行运动的振幅就会不断扩大从而发生蛇行失稳,而蛇行失稳可能对轨道造成损坏,甚至可能导致列车脱轨等严重事故^[2]。在中国,根据《高速铁路工程动态验收技术规范》^[3]和《铁道客车行车安全监测诊断系统技术条件》^[4],判定高速列车转向架横向失稳的条件是转向架构架横向加速度信号的峰值连续 6 次以上(包括 6 次)达到或超过 $8\sim10 \text{ m/s}^2$ 的极限值(或与车辆转向架的原始设计相适应)。但此判别标准只适用于列车已处于完全失稳状态的情况下。在监测数据中发现,高速列车在大幅蛇行前往往还有可能出现振幅明显大于正常状态而又小于蛇行失稳阈值的小幅蛇行运动。小幅蛇行运动首先会影响乘坐舒适性和加剧轮轨磨耗,其次随着时间的推移小幅蛇行还有可能演变为蛇行失稳从而影响列车行车安全^[5]。因此,在列车运行状态监测中对小幅蛇行的识别具有实际意义,一旦小幅蛇行出现发散,可提前对可能出现的大幅蛇行失稳提供预警,从而避免大幅蛇行运动的产生,进一步提高列车运行的安全性。本文提出在列车运行过程中,将列车构架横向加速度信号分为正常、小幅收敛、小幅发散和大幅蛇行 4 类。具体描述见本文 3.1 节。本文希望通过现有监测数据的学习,对蛇行运动的故障完成精准识别。

针对高速列车小幅蛇行故障诊断方法已有研究者在进行研究,刘棋等^[6]提出了基于 D-S 证据理论融合多个传感器数据的高速列车横向运行状态识别方法;冉伟等^[7]结合传统信号处理方法,建立了集合经验模态分解-奇异值分解-局部切空间排列 (ensemble empirical mode decomposition-singular value decomposition-local tangent space alignment, EEMD-SVD-LTSA) 的高速列车蛇行演变特征提取框架。王晓东等^[8]提出基于一维卷积神经网络 (one dimensional convolutional neural network, 1D-CNN) 和长短时记忆网络 (long short-term memory, LSTM) 的识别方法,避免了手动提取特征的局限性;Ning 等^[9-10]提出了一种多尺度排列熵-局部切空间排列 (multiscale permutation entropy-local tangent space alignment, MPE-LTSA) 方法用于监测小幅蛇行运动,降低了特征数据的复杂度,随后又提出了一种非平稳核本征矩阵联合近似对角化 (joint approximate diagonalization of eigenmatrix, JADE) 方法,考虑了数据的非平稳性,能够快速准确地提取信号的非平稳特征。但是基于以上的故障识别研究都没有考虑数据极端不平衡的情况,因此解决此类研究的不平衡

问题具有很大意义。

基于以上问题,本文提出基于条件生成式对抗网络—一维卷积神经网络 (conditional generative adversarial network-one dimensional convolutional neural network, CGAN-1DCNN) 的预测方法。该方法首先使用 CGAN 对原始信号数据进行学习,建立从已知简单分布到原始信号数据分布的映射模型,通过对该模型对原始数据进行采样以增强训练的数据集。最后,使用一维卷积神经网络完成对高速列车蛇行运动的预测。本文在某高铁实际运行线路数据上进行实验,从样本生成和预测结果来看,CGAN-1DCNN 方法的样本生成效果和分类精度均优于其他比较方法。

1 CGAN-1DCNN 算法原理

1.1 GAN

生成式对抗网络 (generative adversarial network, GAN) 是一种强大的生成模型,由 Goodfellow 等^[11]于 2014 年提出,GAN 的结构包含生成器 G 和判别器 D 两个部分。

在具体的训练过程中,生成器 G 的目标是学习真实样本的数据分布,并尽可能地使生成样本与真实样本类似。生成器 G 的输入是一组符合先验分布的随机噪声 Z ,输出是生成样本 $G(Z)$,其分布与真实样本相似。判别器 D 的输入是生成样本 $G(Z)$ 和真实样本 X , D 的目标是通过输出真或假逻辑值来识别真样本和假样本。

在训练过程中, G 和 D 交替训练直到达到纳什均衡,损失函数 \mathcal{L}_{GAN} 如式(1)和(2)所示。

$$\mathcal{L}_{GAN} = \frac{1}{2} \left(\sum_X \log(D(X)) + \sum_Z \log(1 - D(G(Z))) \right) \quad (1)$$

$$\min_{G} \max_{D} \mathcal{L}_{GAN}(D, G) \quad (2)$$

生成器 G 目标是降低该损失函数的值而判别器 D 目标相反,为增大该损失函数的值,在二者的博弈下,最终使得生成器 G 可以完成从高斯分布到目标分布的映射关系,从而可以进行随机的采样来生成样本。

1.2 CGAN

CGAN^[12]是在 GAN 基础上做的一种改进,通过给原始 GAN 的生成器 G 和判别器 D 添加额外的条件信息 Y ,实现条件生成模型。 Y 可以是任何类型的辅助信息,例如类别标签或来自其他模式的数据。图 1 为 CGAN 网络结构。在生成器中,先验输入噪声 Z 和条件信息 Y 组合,在判别器中输入信号和条件信息 Y 组合,其损失函数 \mathcal{L}_{CGAN} 如式(3)和(4)所示。

$$\mathcal{L}_{CGAN} = \frac{1}{2} \left(\sum_X \log(D(X | Y)) + \sum_Z \log(1 - D(G(Z | Y))) \right) \quad (3)$$

$$\min_{G} \max_{D} \mathcal{L}_{CGAN}(D, G) \quad (4)$$

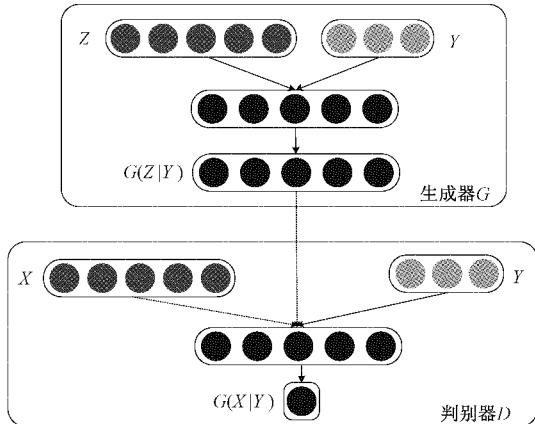


图1 CGAN网络结构

1.3 1DCNN

1DCNN^[13]是在CNN下进行更改,1DCNN的卷积核为一维,适合建立时间序列模型,其主要提取特征的方式为卷积运算,卷积核按照一定步长对原始特征进行线性扫描,通过卷积核向量与对应长度原始信号向量相乘,再通过激活函数,提取特征。其卷积运算如式(5)所示。

$$\mathbf{Y} = \varphi(\mathbf{W}\mathbf{X} + b) \quad (5)$$

式中: \mathbf{Y} 为输出特征向量, \mathbf{X} 为输入特征向量, \mathbf{W} 为卷积核向量参数, b 为偏置项, φ 为激活函数。图2所示为1DCNN网络结构。

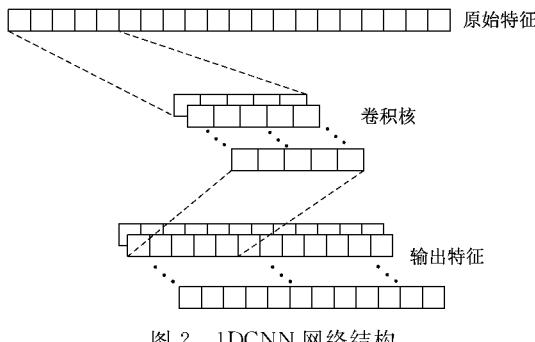


图2 1DCNN网络结构

2 基于CGAN-1DCNN高速列车蛇形失稳预测方法

如图3所示,基于CGAN-1DCNN的高速列车蛇行运动预测方法的具体步骤如下。

- 1) 将预处理好的原始数据划分为训练集和测试集,其中训练集具有高度不平衡的特征,测试集中的数据保持平衡。
- 2) 将测试集中的故障数据组成CGAN的训练集训练CGAN的生成网络和判别网络直到模型达到Nash均衡。
- 3) 对训练好的CGAN模型进行采样得到每个故障类别的生成样本增强数据以达到平衡,使用该平衡后的数据集作为分类模型的训练集。
- 4) 训练1DCNN分类模型,直至该模型的交叉熵损失函数达到收敛。
- 5) 使用平衡的测试集评价该模型的预测结果。

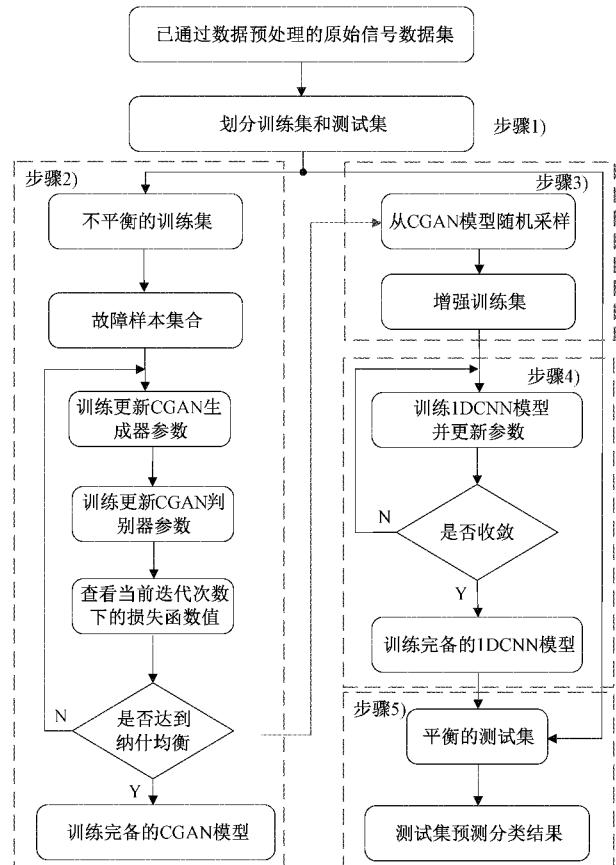


图3 CGAN-1DCNN高速列车蛇形失稳预测方法

3 实验验证与分析

3.1 实验数据说明

本文所使用的实验数据来自中国运行线路下的某型号高速列车在运行过程中出现的异常。通过在该型车的轴箱和构架上安装加速度传感器对加速度信号进行采集,采样频率为2500 Hz,所有数据均按照中国铁路客运安全监测标准^[14]采集。

图4显示转向架构架的横向加速度从小振幅蛇行状态发展到常规蛇行状态。从信号处理的角度来看,这是一个逐渐发散的过程。本文称之为小振幅发散运动(SADH)。有时,横向加速度会从小振幅振荡状态演变为正常状态。从信号处理的角度来看,这是一个逐渐收敛的过程。本文称之为小振幅收敛运动(SACH)。图4所示为小幅蛇行收敛和发散的演变过程。为了区分高速列车不同的横向稳定情况,本文定义了4种情况:正常(无蛇行)、小幅收敛、小幅发散和蛇行失稳。

对于蛇行,框架横向加速度的特征频率仅为3~7 Hz。因此,在预处理阶段,采用了250 Hz重采样方法^[15],并采用了0~10 Hz的低通滤波器。然后,采用零均值平滑方法进行预处理,消除趋势项^[16]。本文将滤波后的横向加速度信号分为4种状态:正常、小幅收敛、小幅发散和蛇行失稳。

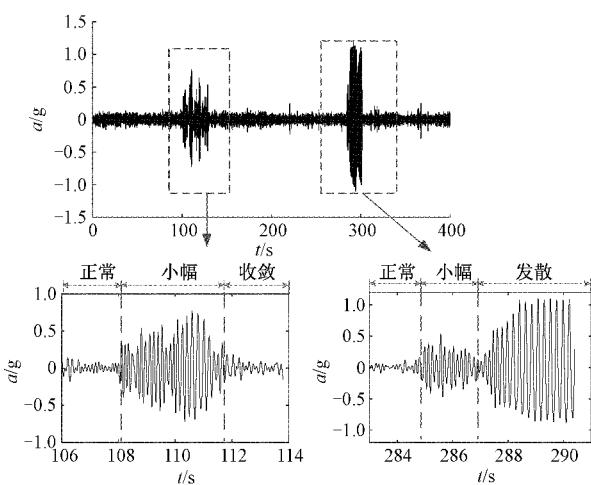


图 4 小幅蛇行收敛和发散的演变过程

为了贴合实际数据不平衡的特点,设置训练样本中正常和每类故障样本比为 100 : 1。训练集和测试集互不交叉,训练集和测试集如表 1 所示。

表 1 训练和测试数据集说明

数据集	正常	小幅收敛	小幅发散	蛇形失稳
训练集	1 000	10	10	10
测试集	10	10	10	10

3.2 模型参数说明

1) CGAN 模型参数

CGAN 的基本模型参数如表 2 所示,除此之外在生成器网络每层结构之间设置动量 0.8 的一维批标准化并以正太分布进行参数初始化,在判别器网络中,设置每层之间的 Dropout 丢弃率为 0.4。在两个网络中的激活函数均设置为 LeakyReLU,设置负斜率为 0.2。CGAN 模型训练中采用均方误差损失函数,Adam 为优化器,生成器和判别器学习率均为 0.000 05, β 系数分别设置为 0.5 和 0.999。

表 2 CGAN 模型参数和输出维度

层数	类型	通道数	输出维度
生成器	输入层	504	X [batch, 200] Z [batch, 1]
	全连接	128	[batch, 128]
	全连接	256	[batch, 256]
	全连接 $\times 2$	512	[batch, 512]
	全连接	1 024	[batch, 1024]
	输出层	200	[batch, 200]
判别器	输入层	204	X [batch, 500] Z [batch, 1]
	全连接 $\times 3$	512	[batch, 512]
	输出层	1	[batch, 1]

2) 1DCNN 模型参数

表 3 所示为 1DCNN 的模型参数,1DCNN 中在每层卷积后采用 ReLU 激活函数,在所有卷积和池化操作完成后,采用全局平均池化的操作,该操作将每个卷积后的特征图求和平均为一个值,减少了计算量的同时也做到了特征信息的保留。1DCNN 采用交叉熵损失函数,优化器选用 Adam, 设置学习率为 0.001, β 系数分别设置为 0.9 和 0.999。

表 3 1DCNN 模型参数和输出维度

层数	类型	卷积核大小	步长	通道数	输出维度
1	一维卷积	8	2	16	[batch, 16, 248]
2	池化层	2	2	—	[batch, 16, 125]
3	一维卷积	8	2	32	[batch, 32, 60]
4	池化层	2	2	—	[batch, 32, 31]
5	一维卷积	4	2	64	[batch, 64, 15]
6	平均池化	—	—	—	[batch, 64, 1]
7	全连接	—	—	4	[batch, 4]
8	Softmax	—	—	—	[batch, 4]

3.3 实验结果与分析

为验证模型的生成效果,将深度学习生成模型领域中与 GAN 同样重要的变分自编码器 (variational auto-encoder, VAE) 作为对比方法,且加入条件参数形成 CVAE,CVAE 模型中的解码器参数与 CGAN 生成器相同,编码器与生成器结构成镜像对应,编码维度为 200,优化器选用 Adam, 学习率设置为 0.000 1。在两个生成模型同时训练 3 000 次 epoch 后,所得的生成结果如图 5 所示。由图 5 看出,两个生成模型可以基本拟合真实情况的分布和效果。如图 5 (a) 所示 CGAN 在生成过程中对原始数据的拟合更加准确,而在图 5 (b) 中可以看出 CVAE 在幅值上的生成表现欠缺,生成的样本幅值偏小。通过生成模型对每个故障类别采样 1 000 个来增强样本空间以达到数据平衡,图 6 所示为 TSNE 降维后该 4 000 个样本的分布情况。

对蛇行的预测效果的评估采用准确率和 F1 分数,F1 分数是一个分类模型召回率和精准率的调和平均值。采用 BP 神经网络和两种机器学习分类方法作为对比实验,其中 BP 的网络采用 Adam 优化器,学习率设置为 0.001,svm 设置正则参数为 1,核函数选用径向基函数,随机森林设置分类树的数目为 100,度量标准设置为 gini 指数。保证模型收敛后的预测结果如表 4 所示,由表 4 看出,在未进行数据平衡前的预测准确率不足 40%,经过数据增强平衡后,预测结果明显提升,其中 CGAN-1DCNN 的组合方法预测准确率达到 97.5%,优于其他对比方法。图 7 所示为表 4 中预测效果最好的 3 组方法的混淆矩阵,由图 7 可以得到

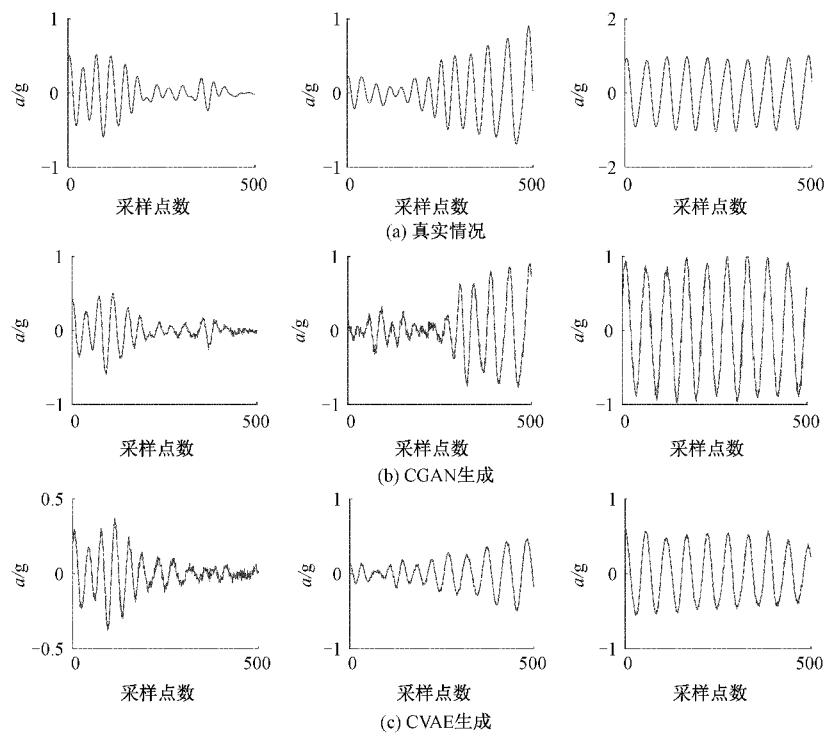


图5 生成效果对比

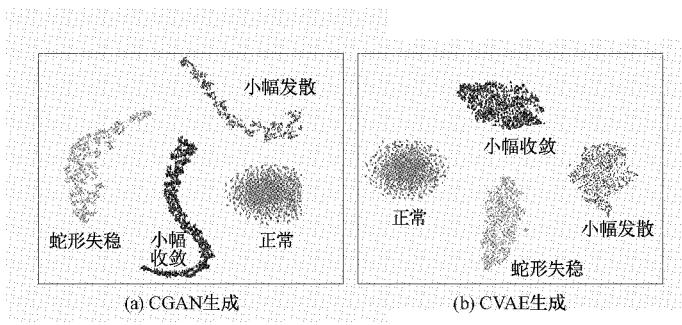


图6 TSNE降维后可视化

在蛇行的预测分类中,正常和大幅的状态都能精准识别,而小幅收敛和小幅发散两种状态较难识别,在CGAN-1DCNN中有一例小幅收敛样本被误分为正常,其余类别均预测正确。

表4 预测分类结果

数据集	正常: 故障 (数量)	模型	准确率/ F1 score/	
			%	%
真实样本	1 000 : 10	CGAN-1DCNN	35.00	22.40
		CGAN-1DCNN	97.50	97.49
	1 000 : 样本 1 000	CGAN-BP	50.00	41.67
		CGAN-SVM	62.50	61.21
		CGAN-RF	47.50	45.17
		CVAE-1DCNN	75.00	73.63

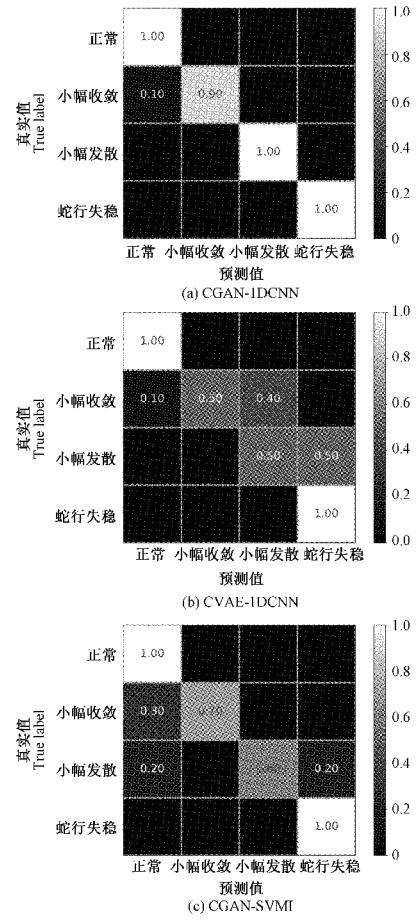


图7 分类混淆矩阵

4 结 论

由于高速列车蛇行运动的实测数据很少,在少样本下很难有效对其进行特征提取和预测,因此本文针对高速列车蛇行运动的状态预测和蛇行故障数据不平衡问题,提出了基于 CGAN-1DCNN 的联合预测方法,经过真实数据验证,得到结论如下:1) CGAN 可以有效地拟合小样本数据的分布,实现对原始数据样本空间的增强;2) CGAN-1DCNN 模型预测分类准确率和 F1 分数高于其他对比方法,能够有效识别小幅收敛,准确识别小幅发散,正常和蛇行失稳 4 种状态。

本文提出的算法本质上是基于原始数据进行拟合,无法生成新的真实数据,基于增强的样本空间较为单一。未来的工作可以侧重于与机械联合仿真相结合,通过仿真获得更多的故障数据,并将仿真数据添加到原始数据中,再进一步通过生成算法达到数据增强的作用。

参考文献

- [1] 张卫华, 李艳, 宋冬利. 高速列车运动稳定性设计方法研究[J]. 西南交通大学学报, 2013(1):5-13.
- [2] OKAMOTO H, KOTANI M, LIN S P, et al. Stabilization control for hunting motion of railway vehicle by gyroscopic damper (experimental analysis using 1/10 scale vehicle model)[J]. Transactions of the Japan Society of Mechanical Engineers, 2008, 74(738): 235-241.
- [3] TB10761-2013, 高速铁路工程动态验收技术规范[S]. 北京: 中国铁道出版社, 2013.
- [4] TB/T 3188-2007, 铁道客车行车安全监测诊断系统技术条件[S]. 北京: 中国铁道出版社, 2007.
- [5] 孙丽霞. 高速列车横向运动稳定性和动态脱轨理论分析及评价方法[D]. 北京: 中国铁道科学研究院, 2014.
- [6] 刘棋, 宁静, 叶运广, 等. 基于 D-S 证据理论高速列车横向失稳故障判别研究[J]. 中国测试, 2017, 43(7): 103-107.
- [7] 冉伟, 宁静, 陈杨, 等. 基于 EEMD-SVD-LTSA 的高速列车蛇行演变特征提取框架[J]. 电子测量技术, 2019, 42(5):1-5.
- [8] 王晓东, 宁静, 陈春俊. 1D-CNN 和 LSTM 高速列车横向稳定性状态识别研究[J]. 中国测试, 2020, 46(11): 25-30.
- [9] NING J, CUI W, CHONG C, et al. Feature recognition of small amplitude hunting signals based on the MPE-LTSA in high-speed trains [J]. Measurement, 2019, 131: 452-460.
- [10] NING J, FANG M, RAN W, et al. Rapid multi-sensor feature fusion based on non-stationary kernel JADE for the small-amplitude hunting monitoring of high-speed trains[J]. Sensors, 2020, 20(12): 3457.
- [11] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. Advances in Neural Information Processing Systems, 2014.
- [12] MIRZA M, OSINDERO S. Conditional generative adversarial nets [J]. ArXiv Preprint, 2014, ArXiv:1411.1784.
- [13] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2019, 16(7): 4681-4690.
- [14] 中华人民共和国铁道部. 高速铁路工程动态验收技术规范[S]. 北京: 中国铁道科学研究院, 2013.
- [15] 林建辉. CRH2 型动车组线路实车脱轨试验车辆测试试验报告[R]. 成都: 西南交通大学牵引动力国家重点实验室, 2012.
- [16] 于波, 韩玉斌. 基于 STM32 的振动信号采集系统设计[J]. 电子测量技术, 2020, 43(4):148-152.

作者简介

宁静,硕士研究生,主要研究方向为高速列车信号的时间序列分析和故障诊断。

E-mail: ningyunzhi@my.swjtu.edu.cn

宁静(通信作者)副教授,工学博士,主要研究方向为机器学习(大数据挖掘)在高速列车中的应用、智能化状态监测与故障诊断、机电系统数字化设计与控制。

E-mail: ningjing@swjtu.edu.cn