

# 基于模糊聚类和 CNN-BIGRU 的轨道电路故障预测\*

林俊亭<sup>1</sup>, 王帅<sup>1</sup>, 刘恩东<sup>1</sup>, 王阳<sup>2</sup>

(1. 兰州交通大学自动化与电气工程学院 兰州, 730070)

(2. 中国国家铁路集团有限公司铁路安全研究中心 北京, 100081)

**摘要** 针对轨道电路稳态环境下故障诊断时效性不足的问题,提出一种基于 Gath-Geva (GG)模糊聚类对轨道电路退化状态进行划分,并利用卷积神经网络(convolutional neural network, 简称 CNN)和双向门控循环单元(bi-directional gated recurrent unit, 简称 BIGRU)进行轨道电路故障预测的方法。首先,通过集中监测设备获取 ZPW-2000 轨道电路各类故障发生前一定时间内的正常工作数据;其次,通过核主成分分析进行特征降维和 GG 模糊聚类对轨道电路性能退化状态进行阶段划分,识别不同的退化状态;最后,利用 CNN-BIGRU 混合神经网络挖掘轨道电路不同故障类型数据特征,对轨道电路退化状态所对应的故障类型进行预测。实验结果表明,该算法可以精确划分轨道电路退化状态并实现故障预测,CNN-BIGRU 预测模型分类精确度可达 97.62%,运行时间仅为 13.18 s,能够为轨道电路的多模式健康状态识别提供一种有效的方法。

**关键词** 轨道电路;GG 模糊聚类;退化状态划分;卷积神经网络-双向门控循环单元;故障预测

**中图分类号** U284.2

## 引言

ZPW-2000 系列无绝缘轨道电路是我国高速铁路列控系统地面设备的重要组成部分,其一旦发生故障会直接影响到铁路运输效率,甚至危及列车运行安全<sup>[1]</sup>。由于轨道电路大多数部件分布于室外铁路两侧,其故障类型复杂,现场设备维护效率较低。因此,通过引入相关智能诊断算法,提高铁路故障诊断精度和诊断效率是当前研究的热点。

目前,针对轨道电路故障诊断的研究大多集中在不同故障类型的特征提取和故障分类中。文献[2]提出了一种模拟退火和遗传算法优化支持向量机的故障诊断方法。文献[3]基于二端口网络建立轨道电路等效模型,实现了对补偿电容的准确监测。文献[4]运用优化后的深度置信网络构建轨道电路故障诊断模型,分类准确度较高。但是,将轨道电路运行状态简单划分为正常和故障进行诊断很难满足轨道电路设备的维护需求,需要对轨道电路退化状态划分和故障预测进行研究。轨道电路发生故障的本质是轨道电路参数发生异常变化,从而引发轨道信号幅值经历暂态过渡到稳态<sup>[5]</sup>,其退化过程通常存在一个从正常到故障的变化阶段。因此,及时、准确地识别轨道电

路退化状态并预测其可能发生的故障类型能够合理调整现场设备的维护周期,阻止轨道电路运行状态持续恶化,提高了轨道电路的安全性。

轨道电路性能退化的过程具有随机性、模糊性等特点,其本质上是模式识别问题。聚类分析方法能够挖掘数据之间的相似度关系,从而无监督地将数据划分到不同的类别中。典型的聚类方法包括 K 均值聚类、模糊 C 均值(fuzzy center means, 简称 FCM)聚类及 GG 聚类等。文献[6]提出了基于经验模态分解和 K 均值聚类的退化状态评估方法。文献[7]将 FCM 聚类运用于滚动轴承退化状态划分,实现了退化特征的自动聚类。GG 聚类算法通过引入基于模糊最大似然估计的聚类范数,能够反应不同形状和方向的数据类别,聚类精度较高。文献[8]采用小波包分解获取转辙机退化特征,结合 GG 聚类方法划分出转辙机不同退化阶段。

深度学习作为目前数据驱动故障诊断的主流方法,采用端到端的网络结构实现了故障特征的智能提取。文献[9]针对铁路轨道电路的故障诊断问题,提出了一种具有长短期记忆(long short-term memory, 简称 LSTM)的循环神经网络,利用生成模型的合成数据对网络进行训练和故障诊断。文献[10]采

\* 中国铁道科学研究院科研基金资助项目(2021YJ205)

收稿日期:2022-05-10;修回日期:2022-06-20

用 CNN 对调谐区机车信号电压进行特征提取,实现了无绝缘轨道电路调谐区的故障诊断。CNN 卷积神经网络能够有效挖掘数据特征,对原始输入数据具有更强的表达能力。门控循环单元(gated recurrent unit, 简称 GRU)<sup>[11]</sup>作为 LSTM 的一种变体,其参数较少,收敛速度更快。文献[12]利用 1 维 CNN 提取数据特征,结合 GRU 实现了滚动轴承的故障诊断。

由于轨道电路分类结果受历史数据和未来数据的共同影响,所以笔者选用 BIGRU<sup>[13]</sup>结合 CNN 作为轨道电路故障预测模型。首先,通过集中监测系统获取轨道电路各类故障发生前一定时间内的正常运行数据,分析其退化过程中的参数变化规律,并采用 GG 模糊聚类划分其不同退化状态;其次,将故障数据和退化数据共同输入到 CNN-BIGRU 卷积双向门控循环神经网络,预测轨道电路可能发生的故障类别。

## 1 基础理论

### 1.1 GG 模糊聚类

由于轨道电路的退化状态数目和边界难以确定,选择无监督聚类算法中的模糊聚类分析数据之间的潜在关系,通过计算各样本之间的模糊距离,进而划分出不同的退化类别<sup>[14]</sup>。GG 模糊聚类是在 FCM 聚类的基础上,使用模糊最大似然估计来衡量样本之间的距离,可以进行非规则分布的不同形状方向的数据分析。

假设轨道电路正常非故障数据样本集合  $X = \{x_1, x_2, \dots, x_H\}$ ,  $H$  为样本个数,其中任意一个元素  $x_k (k = 1, 2, \dots, H)$  均有  $d$  个特性指标,即  $x_k = \{x_{k1}, x_{k2}, \dots, x_{kd}\}$ , 现将其划分为  $c$  类。假设每个类别的聚类中心向量  $V = (v_1, v_2, \dots, v_c)$ , 隶属度划分矩阵  $U = [\mu_{ik}]_{c \times H}$ , 其中  $\mu_{ik} \in [0, 1]$  表示第  $k$  个样本对第  $i$  类的隶属度,  $i = 1, 2, \dots, c$ 。GG 模糊聚类通过迭代  $(U, V)$ , 使目标函数  $J_m$  取得最小值

$$J_m(U, V) = \sum_{i=1}^c \sum_{k=1}^H (\mu_{ik})^m D_{ik}^2 \quad (1)$$

其中:  $m$  为加权指数,  $m$  越大说明各个类别之间的重叠越多,一般取 2;  $D_{ik}^2$  为模糊最大似然距离。

迭代调整步骤如下。

1) 计算聚类中心

$$v_i^{(l)} = \frac{\sum_{k=1}^H (\mu_{ik}^{(l-1)})^m x_k}{\sum_{k=1}^H (\mu_{ik}^{(l-1)})^m} \quad (1 \leq i \leq c) \quad (2)$$

$$u(x_k, v_i) = \exp\left(\frac{1}{2} (x_k - v_i^{(l)})^T A_i^{-1} (x_k - v_i^{(l)})\right) \quad (3)$$

其中:  $A_i$  为第  $i$  个聚类的协方差矩阵。

2) 更新分类矩阵

$$\mu_{ik}^{(l)} = \frac{1}{\sum_{j=1}^c \left(\frac{D_{ik}(x_k, v_i)}{D_{jk}(x_k, v_j)}\right)^{\frac{2}{m-1}}} \quad (4)$$

其中:  $1 \leq i \leq c; 1 \leq k \leq H$ 。

直到条件满足  $\|U^{(l)} - U^{(l-1)}\| < \epsilon$ , 终止迭代, 得到聚类中心  $V$  和隶属度矩阵  $U$ 。

### 1.2 CNN 卷积神经网络

CNN 通常由卷积层、池化层和全连接层构成<sup>[15]</sup>, 因其在保持原始数据信息不变的条件下自动提取特征的特点, 在以人工智能为基础的故障诊断领域中得到广泛应用, 具有较强的鲁棒性。轨道电路电压参数存在局部相关性, 利用 CNN 能够较好地提取特征信息。CNN 通过多个卷积池化层交替连接获取轨道电路参数变化的局部特征, 并将处理后的信息输入到 BIGRU 网络进行轨道电路故障预测。

### 1.3 GRU 门控循环单元

GRU 作为 LSTM 的一种变体, 可以更好地处理具有时间关联性的轨道电路数据, 其计算过程简单, 参数更少, 解决了 LSTM 收敛速度慢的问题, 因此笔者选用 GRU 结合 CNN 建立轨道电路故障预测模型。GRU 结构如图 1 所示, 主要由更新门  $r_t$  和重置门  $z_t$  组成。首先, 通过上一时刻传输状态  $H_{t-1}$  和当前时刻输入状态  $X_t$  获取 2 个门状态; 其次, 更新门决定是否对信息进行保留和添加, 控制前一时刻输出隐藏状态对当前时刻输出状态的影响; 然后, 重置门决定哪些信息被丢弃, 控制前一时刻中信息的忽略程度; 最后, 保留当前单元信息并传递到下一个单元  $H_t$ 。其传递过程由式(5)~(8)表示

$$r_t = \sigma(W_r X_t + U_r H_{t-1} + b_r) \quad (5)$$

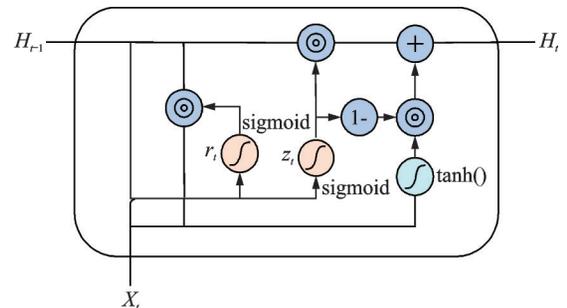


图 1 GRU 结构

Fig.1 GRU structure

$$z_t = \sigma(W_z X_t + U_z H_{t-1} + b_z) \quad (6)$$

$$\tilde{H}_t = \tanh(W X_t + \tilde{U}(r_t \odot H_{t-1})) \quad (7)$$

$$H_t = (1 - z_t)H_{t-1} + z_t \tilde{H}_t \quad (8)$$

其中： $\tilde{H}_t$ 为候选隐藏状态； $H_t$ 为最终输出的状态； $H_{t-1}$ 为 $t-1$ 时刻的状态信息； $W_r, W_z, W, b_r, b_z$ 分别为权重矩阵和偏置项； $U_z, U_r, \tilde{U}$ 为GRU的权值矩阵； $\sigma$ 为sigmoid非线性激活函数； $\odot$ 代表矩阵的点乘运算。

由于轨道电路参数当前状态受前后输出状态的共同影响，笔者采用BIGRU通过2层GRU对CNN提取的局部特征进行进一步特征提取和选择，从而提高GRU的性能。BIGRU结构如图2所示，该网络由一个正向GRU和一个反向GRU上下叠加而成，每个GRU沿相反方向对输入序列进行处理，然后将2个输出向量连接起来作为模型隐藏状态输出 $H$ ，即

$$H = \vec{H} + \overleftarrow{H} \quad (9)$$

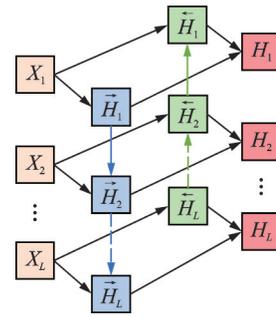


图2 BIGRU结构

Fig.2 BIGRU structure

### 1.4 模型整体结构和流程

笔者提出的基于GG模糊聚类和CNN-BIGRU模型的轨道电路故障预测框架如图3所示，通过GG模糊聚类划分轨道电路退化状态，并结合CNN-BIGRU模型挖掘退化数据与故障数据之间的数据特征，最终实现轨道电路故障智能预测。

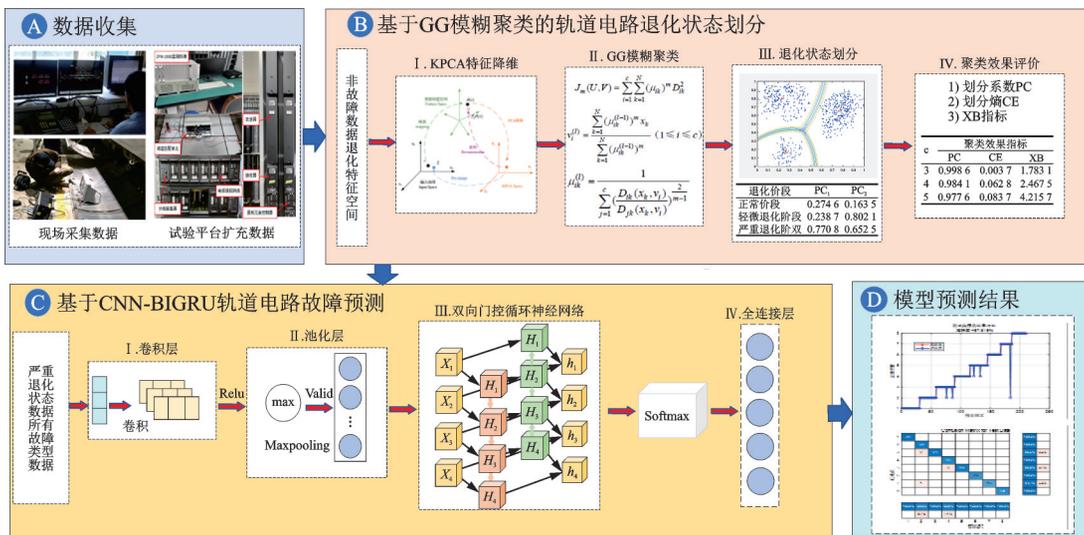


图3 基于GG模糊聚类和CNN-BIGRU模型的轨道电路故障预测框架图

Fig.3 Frame diagram of track circuit fault prediction based on GG fuzzy clustering and CNN-BIGRU model

## 2 ZPW-2000 轨道电路故障类型

区间ZPW-2000无绝缘轨道电路由室内外设备构成，其结构如图4所示。室内设备包括发送器、接收器、衰耗冗余控制器、电缆模拟网络、站防雷、通信接口板、集中监测机和分线采集器等；室外设备包括钢轨、调谐匹配单元、空心线圈、补偿电容和传输电缆等。

笔者以轨道电路运行过程中产生的状态数据为基础，从集中监测系统中获取各设备电压参数，通过引入智能算法挖掘数据内在特征，进而实现轨道电路故障预测。ZPW-2000轨道电路典型故障模式如表1所示。

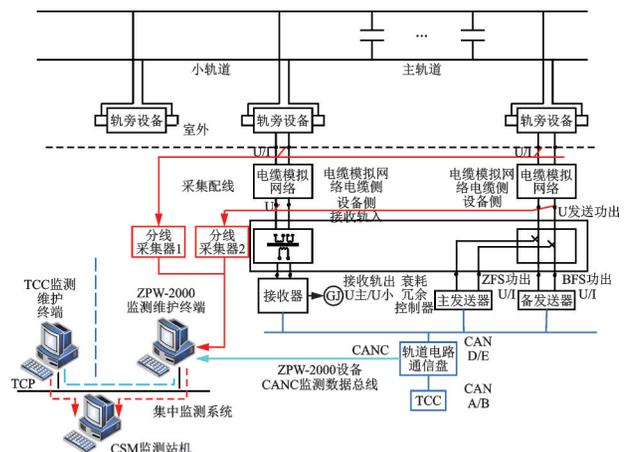


图4 ZPW-2000无绝缘轨道电路结构示意图

Fig.4 Structure diagram of ZPW-2000 jointless track circuit

表1 轨道电路典型故障模式

Tab.1 Typical failure modes of track circuit

故障编号	故障类别
F <sub>1</sub>	发送器故障
F <sub>2</sub>	发送端调谐匹配单元故障
F <sub>3</sub>	主轨故障
F <sub>4</sub>	接收端调谐匹配单元故障
F <sub>5</sub>	小轨故障
F <sub>6</sub>	衰耗冗余控制器故障
F <sub>7</sub>	分线采集器故障
F <sub>8</sub>	接收器故障

### 3 试验验证

笔者提出的退化状态划分和故障预测整体流程如图5所示。首先,从集中监测系统获取轨道电路各类故障发生前正常电压数据和发生后故障数据,划分训练集和测试集;其次,对退化数据进行核主成分分析(kernel principle component analysis,简称KPCA)提取退化特征,通过GG模糊聚类实现轨道电路退化状态划分;然后,利用CNN提取故障数据特征图的局部特征,考虑时间关联性的条件下引入BIGRU建立“端到端”的轨道电路故障预测模型;最后,在测试集上验证模型分类的有效性。

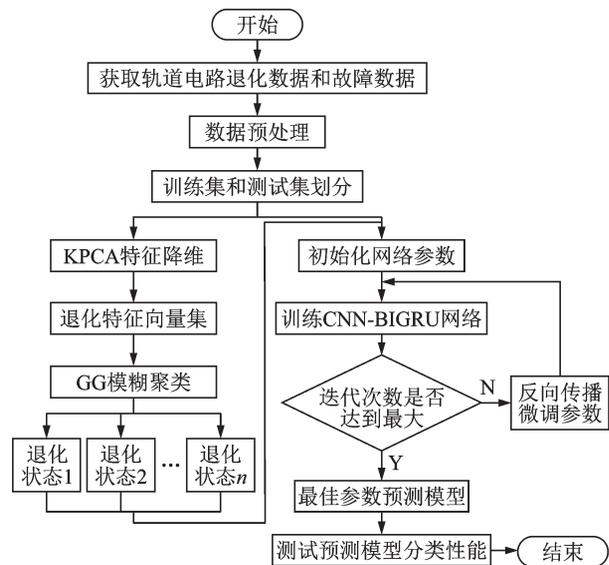


图5 退化状态划分和故障预测整体流程图

Fig.5 Overall flow chart of degradation state division and fault prediction

#### 3.1 轨道电路试验数据获取

在某铁路局电务段集中监测系统中获取试验数据并通过兰州交通大学轨道电路试验平台进行数据扩充,ZPW-2000轨道电路试验平台如图6所示。该

平台包含与现场轨道电路相同的室内外电气设备及监测维护系统,所采数据与现场采集真实数据差别较小,均符合轨道电路技术规范,可用于试验验证。集中监测系统采集轨道电路相关参数较多,如区段载频、小轨低频及功出电压等。笔者选择14个监测参数作为数据集的输入,如表2所示。



图6 ZPW-2000轨道电路试验平台

Fig.6 ZPW-2000 track circuit test platform

表2 监测参数

Tab.2 Monitoring parameters

序号	监测参数	标准值
1	发送电源电压 C <sub>1</sub> /V	[24±1]
2	功出电压 C <sub>2</sub> /V	[73,181]
3	功出电流 C <sub>3</sub> /mA	[200,500]
4	主轨道输入电压 C <sub>4</sub> /mV	≥170
5	小轨道输入电压 C <sub>5</sub> /mV	≥42
6	轨出1电压 C <sub>6</sub> /mV	≥240
7	轨出2电压 C <sub>7</sub> /mV	[100,145]
8	GJ电压 C <sub>8</sub> /V	≥24V
9	XG电压 C <sub>9</sub> /V	≥24V
10	XGJ电压 C <sub>10</sub> /V	≥24V
11	分线盘送端电缆侧电压 C <sub>11</sub> /V	≤设备电压
12	分线盘送端设备侧电压 C <sub>12</sub> /V	≈功出电压
13	分线盘受端电缆侧电压 C <sub>13</sub> /V	≥防雷变压器电压
14	分线盘受端设备侧电压 C <sub>14</sub> /V	≈衰耗输入电压

ZPW-2000监测子系统采集轨道电路模拟量的周期为250ms,每分钟采集240个,一天采集的数据量更为庞大<sup>[16]</sup>。对轨道电路各类故障发生前48h内各参数数据进行采集,固定间隔为1h,取1min存储的60个值的平均值。对故障类型数据,按故障报警后到维修前1min为间隔,取其中240个值的平均值,获得ZPW-2000A无绝缘轨道电路的部分监测参数如表3所示,其中样本6和样本7为试验平台采集数据,符合轨道电路技术指标规范。为了满足数据类别的平衡性,现场实际采集数据经轨道电路试验平台数据扩充后,构建的试验样本数据见表4。

表3 轨道电路监测记录

Tab.3 Track circuit test record

样本编号	监测参数														故障类型
	$C_1$	$C_2$	$C_3$	$C_4$	$C_5$	$C_6$	$C_7$	$C_8$	$C_9$	$C_{10}$	$C_{11}$	$C_{12}$	$C_{13}$	$C_{14}$	
1	23.8	55	114	192	61	271	103	27.8	29.5	32.4	41	54	1.52	7.94	$F_1$
2	23.7	112	412	84	55	312	128	32.7	33.5	31.2	108	113	1.30	8.21	$F_2$
3	23.6	124	357	91	28	124	151	35.8	34.8	35.6	110	123	0.60	6.58	$F_3$
4	24.5	142	431	198	0.04	356	81	28.1	42.1	28.4	124	142	1.90	5.92	$F_4$
5	24.3	97	298	86	34	288	68	25.8	35.1	27.8	78	94	1.28	8.80	$F_5$
6	23.2	165	355	221	62	361	137	32.1	17.2	25.9	123	160	2.28	5.25	$F_6$
7	24.8	101	364	208	56	265	115	16.8	29.1	30.5	81	104	3.47	9.04	$F_7$
8	24.1	177	287	241	49	284	124	28.7	28.6	27.5	128	169	3.21	9.39	$F_8$

表4 试验样本数据表

Tab.4 Data sheet of test samples

数据类型	训练样本	测试样本	数据类型	训练样本	测试样本
退化数据	720	—	$F_5$	62	30
$F_1$	61	30	$F_6$	57	22
$F_2$	60	28	$F_7$	61	19
$F_3$	58	31	$F_8$	60	24
$F_4$	64	26			

### 3.2 轨道电路退化状态划分

为了直观地显示特征提取和聚类的效果,利用KPCA将原始14维监测数据特征变换为2维空间

内的2个特征 $PC_1$ 和 $PC_2$ ,从而实现降维,归一化之后采用GG聚类对轨道电路性能退化状态进行聚类。确定最佳聚类数目对轨道电路退化状态划分具有重要意义,根据铁路复杂设备状态变化规律<sup>[17]</sup>,分别设置聚类数目 $c$ 为3,4,5,加权指数 $m$ 为2,迭代终止容差 $\epsilon$ 为0.000 1。为了确定最优聚类数目,采用聚类有效性指标进行对比试验,有效性指标包括划分系数(partition coefficient,简称PC)、划分熵(classification entropy,简称CE)和XB(Xie-Beni)指标。对轨道电路非故障720组数据进行聚类分析,通过迭代使目标函数 $J_m$ 取得最小值,得到退化状态的聚类中心,不同聚类数目等高线聚类效果如图7所示。

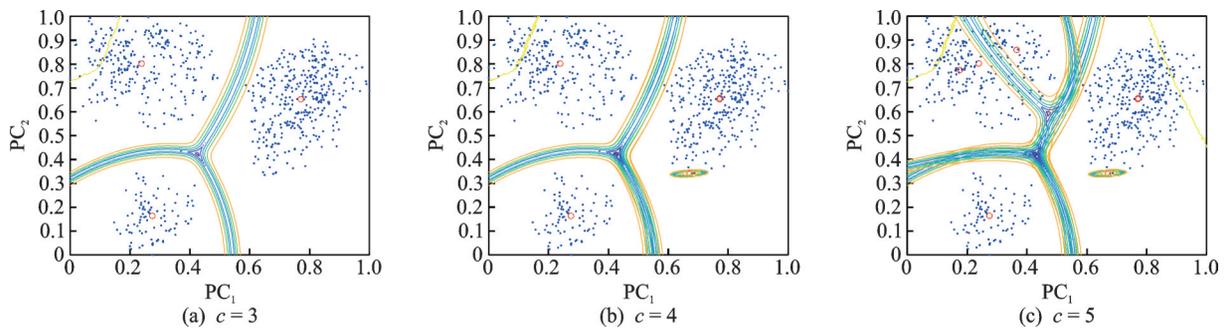


图7 不同聚类数目等高线聚类效果图

Fig.7 Contour clustering effect of different clustering numbers

图7(a)中3种类型的数据分别聚集在退化中心附近,各类别并未出现混叠,且间距较大;图7(b)和(c)各类别出现混叠,且出现错误聚类情况。不同退化阶段定量评价结果如表5所示,由表可知:当聚类数目 $c=3$ 时,聚类分析指标PC为0.998 6,与 $c=4$ 和 $c=5$ 相比更接近于1;CE为0.003 7,与 $c=4$ 和 $c=5$ 时相比更接近于0;XB为1.783 1,均小

于其他2种情况。由聚类有效性可知,分类系数越接近于1,分类熵越接近于0,XB指标越小,聚类效果越好。因此,确定退化状态数目 $c=3$ 。通过结合现场实际情况,笔者将轨道电路退化状态划分为正常、轻微退化、严重退化3种状态,其聚类中心坐标如表6所示。ZPW-2000轨道电路健康状态划分如表7所示。

表 5 不同退化阶段定量评价结果

Tab.5 Quantitative evaluation results of different degradation stages

c	聚类效果指标		
	PC	CE	XB
3	0.998 6	0.003 7	1.783 1
4	0.984 1	0.062 8	2.467 5
5	0.977 6	0.083 7	4.215 7

表 6 3种阶段的聚类中心坐标

Tab.6 Cluster center coordinates of three stages

阶段	PC <sub>1</sub>	PC <sub>2</sub>
正常阶段	0.274 6	0.163 5
轻微退化阶段	0.238 7	0.802 1
严重退化阶段	0.770 8	0.652 5

表 7 ZPW-2000 轨道电路健康状态划分

Tab.7 Health status division of ZPW-2000 track circuit

等级	安全性描述	危险性描述
正常	轨道电路各部件参数为额定值,设备状态较好	发生故障的概率较低
轻微退化	轨道电路各部件电气参数偏离额定值较少,产生轻微波动,设备不太安全,加强监测力度	发生故障的概率在可控范围之内
严重退化	轨道电路各部件电气参数偏离额定值较多,波动程度较大,特征信息较弱,设备需进行检查	设备很有可能发生故障,需在维护周期内尽快安排检查
故障	轨道电路故障特征明显,电压参数超出额定值,需马上安排电务人员进行维修	设备发生故障,需要马上安排维修

### 3.3 轨道电路故障预测

当轨道电路处于正常和轻微退化状态时,传感器采集到的相关电压参数发生轻微波动,变化幅度较低,持续时间较短,其发生故障的可能性较低,工作人员只需加强监测力度即可;当设备处于严重退化状态时,监测参数产生较为明显的故障特征,设备很有可能即将发生故障。将轨道电路严重退化数据和  $F_1 \sim F_8$  这 8 种故障类型数据输入至 CNN 进行特征提取,再将输出的特征图输入到 BIGRU 进行优化训练,最终得到轨道电路故障预测结果。

为了进一步证明 CNN 的特征提取能力,利用 t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, 简称 t-SNE) 对 CNN 提取的训练集故障

类型数据和测试集严重退化数据降维到 2 维空间内进行可视化分析及归一化处理,输出特征二维可视化如图 8 所示。

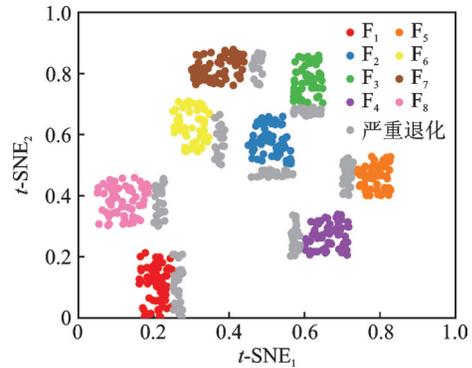


图 8 输出特征二维可视化

Fig.8 2D visualization of output features

由图 8 可以看出,轨道电路 8 种故障数据特征分布在不同空间位置,无相互重叠部分,故障分类明显。测试集各类型严重退化数据之间距离差别较大,与各类型故障数据相隔最近,且有重叠区域。这说明轨道电路当前所处的严重退化状态即将为故障状态,需及时进行维修检查,证明了 CNN 在特征提取方面的优异性。

#### 3.3.1 模型设置

预测模型输入数据大小为  $14 \times 1 \times 1$ , CNN 网络由 2 层卷积层和 1 层池化层构成,卷积核数目  $N$  设置为 16 和 32,卷积步长  $S$  为 1。选择 Relu 函数作为激活函数可以训练更深,迭代速度更快。通过 2 次卷积后进行最大池化,最终输出 1 维特征向量并输入至 BIGRU。BIGRU 设为 2 层,隐藏层单元为 5,激活函数选择 Relu 函数。Dropout 设为 0.5,最后通过全连接层输出预测结果。训练过程采用 Adam 自适应优化器,学习率为 0.001, BatchSize 为 200, Epochs 训练次数为 300。

#### 3.3.2 试验结果分析

将训练集中轨道电路各故障类型数据输入到网络进行训练,其过程如图 9 所示。由仿真结果可以发现,模型迭代次数达到 200 次左右后,训练集准确率和损失值逐渐趋于平稳,准确率最终达到 98% 左右,损失值接近于 0,训练时间为 13.18 s。这说明模型参数通过迭代取得了最优值,得到了较好的预测模型。

将测试集严重退化数据输入到预测模型,得到试验预测结果如图 10 所示。由图 10(a)可知,在 210 个测试样本中共有 5 个样本被错误预测到其他故障

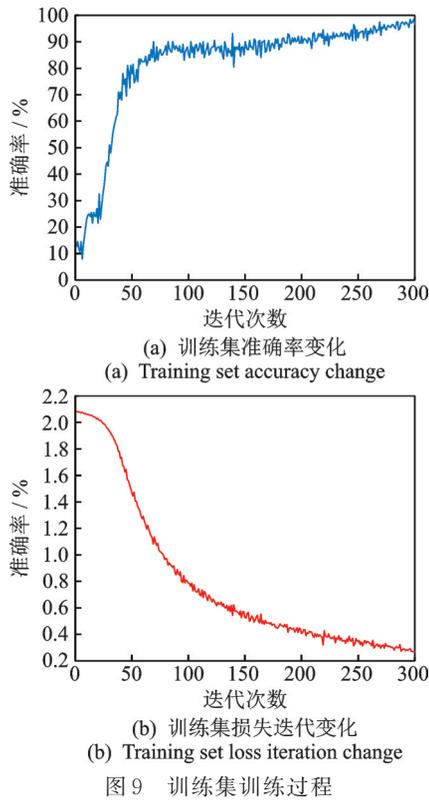


图9 训练集训练过程

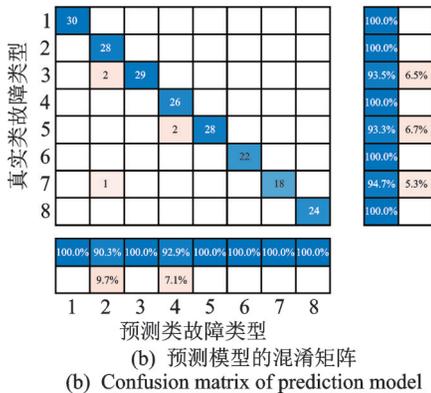
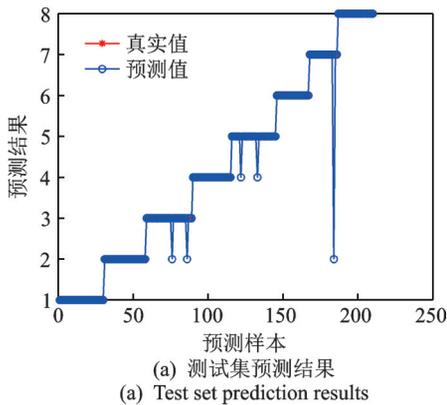


图10 试验预测结果

类别,具体为:第3类故障中(主轨故障)有2个样本被错误划分到第2类(发送端调谐匹配单元故障);第5类故障中(小轨故障)有2个样本被错误划分到

第4类(接收端调谐匹配单元故障);第7类故障(分线采集器故障)中有1个样本被错误划分到第2类(发送端调谐匹配单元故障),平均准确率为97.62%。由图8输出特征可知,故障3和故障7距离故障2较近,故障4和故障5有相似的样本点,导致预测出现错误判断。图10(b)混淆矩阵中横纵坐标1~8表示 $F_1 \sim F_8$ 这8种轨道电路故障类型,矩阵的对角线表示每类样本准确识别的个数。从图中可以看出:对于第 $F_1, F_2, F_4, F_6$ 和 $F_8$ 这5种故障类别预测结果,模型完全识别正确,达到了100%的识别率;对于其他3类故障识别准确率分别达到93.5%,93.3%和94.7%,验证了本预测模型的可行性。

3.3.3 与其他算法对比分析

为进一步验证本研究预测模型的有效性,利用相同数据集进行消融试验及不同算法模型对比分析,包括支持向量机(support vector machine,简称SVM)和LSTM。其中:CNN参数与本研究参数设置一致;SVM选用高斯径向基核函数;LSTM隐藏层单元设置为5。不同算法预测结果如表8所示。

表8 不同算法预测结果

模型结构	平均准确率%	t/s
CNN	90.95	15.21
CNN-SVM	91.90	23.34
CNN-GRU	94.28	16.46
CNN-LSTM	95.24	17.81
CNN-BIGRU	97.62	13.18

由表8可知:CNN结合SVM,GRU和LSTM组合预测模型的平均准确率均高于单纯CNN模型;LSTM和GRU的平均准确率均高于SVM,说明了深度学习在故障诊断领域的优越性;在训练时间上GRU优于LSTM。综合双向信息的CNN-BIGRU,考虑了任一时刻轨道电路参数的整体信息,对于轨道电路故障预测具有更明显的优势,平均准确率最大值达到97.62%,较其余4种模型准确率分别提高了6.67%,5.72%,3.34%和2.38%,且缩短了运行时间,证明了本研究预测模型可以对现场轨道电路即将发生的故障类型进行准确预测。

4 结论

1) 轨道电路在运行过程中存在暂态变化,GG模糊聚类能够在保持聚类精度的同时准确地划分轨道电路退化状态,聚类指标表明其聚类效果较好。

2) CNN-BIGRU 故障预测模型在不丢失原始数据信息的前提下,自动提取具有时间依赖性轨道电路参数的变化特征并实现分类识别,其平均准确率达到 97.62%。通过消融及对比试验分析,进一步证明了该模型具有更好的特征提取能力和更高的准确率,能够较为准确地预测轨道电路未来可能发生的故障类型。

### 参 考 文 献

- [1] 李文海. ZPW-2000A 移频自动闭塞系统原理、维护和故障处理[M]. 北京:中国铁道出版社,2010: 6-8.
- [2] 陈光武,高亚丽,焦相萌. 基于自适应变异 SAPSO-LSSVM 的轨道电路故障诊断[J]. 北京交通大学学报, 2021,45(2):1-7.  
CHEN Guangwu, GAO Yali, JIAO Xiangmeng. Track circuit fault diagnosis based on adaptive mutation SAPSO-LSSVM[J]. Journal of Beijing Jiaotong University, 2021,45(2):1-7. (in Chinese)
- [3] ZHANG W Y, ZHANG B G, XU L M, et al. Modelling and fault diagnosis of railroad jointless track circuit [J]. EEA-Electrotehnica, Electronica, Automatica, 2019,67(1):76-82.
- [4] ZHENG Z Y, DAI S H, XIE X X. Research on fault detection for ZPW-2000A jointless track circuit based on deep belief network optimized by improved particle swarm optimization algorithm[J]. IEEE Access, 2020, 8:175981-175997.
- [5] 赵斌,张友鹏. 基于傅里叶变换结合 Q-D 算法的轨道电路暂态分析[J]. 铁道学报, 2016,38(3):78-83.  
ZHAO Bin, ZHANG Youpeng. Transient analysis of track circuit based on Fourier transform and Q-D algorithm[J]. Journal of the China Railway Society, 2016, 38(3):78-83. (in Chinese)
- [6] RAI A, UPADHYAY S H. Bearing performance degradation assessment based on a combination of empirical mode decomposition and k-medoids clustering [J]. Mechanical Systems and Signal Processing, 2017, 93:16-29.
- [7] WANG B, HU X, LI H R. Rolling bearing performance degradation condition recognition based on mathematical morphological fractal dimension and fuzzy C-means[J]. Journal of the International Measurement Confederation, 2017, 109:1-8.
- [8] 武晓春,楚昕. 基于小波包分解与 GG 模糊聚类的转辙机退化阶段划分研究[J]. 铁道学报, 2022, 44(1): 79-85.  
WU Xiaochun, CHU Xin. Research on division of degradation stage of turnout equipment based on wavelet packet decomposition and GG fuzzy clustering[J]. Journal of the China Railway Society, 2022, 44(1): 79-85. (in Chinese)
- [9] BRUIN de T, VERBERT K, BABUŠKA R. Railway track circuit fault diagnosis using recurrent neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(3):523-533.
- [10] 田粉霞,杨世武,崔勇,等. 基于改进卷积神经网络的无绝缘轨道电路调谐区故障诊断[J]. 铁路计算机应用, 2020,29(6):58-63,74.  
TIAN Fenxia, YANG Shiwu, CUI Yong, et al. Fault diagnosis in tuning area of jointless track circuit based on improved convolutional neural network[J]. Railway Computer Application, 2020,29(6):58-63,74. (in Chinese)
- [11] KANG K, SUN H B, ZHANG C K, et al. Short-term electrical load forecasting method based on stacked auto-encoding and GRU neural network [J]. Evolutionary Intelligence, 2019,12(3):385-394.
- [12] LUI H Y, MA R Z, LI D Y, et al. Machinery fault diagnosis based on deep learning for time series analysis and knowledge graphs[J]. Journal of Signal Processing Systems, 2021,93(12):1433-1455.
- [13] ZHANG X, HE C, LU Y P, et al. Fault diagnosis for small samples based on attention mechanism[J]. Journal of the International Measurement Confederation, 2022,187:1-14.
- [14] WU X H, ZHOU H X, WU B, et al. A possibilistic fuzzy Gath-Geva clustering algorithm using the exponential distance [J]. Expert Systems with Applications, 2021,184:1-11.
- [15] 吴耀春,赵荣珍,靳伍银,等. 面向数据不平衡的卷积神经网络故障辨识方法[J]. 振动、测试与诊断, 2022, 42(2):299-307.  
WU Yaochun, ZHAO Rongzhen, JIN Wuyin, et al. Data imbalance oriented convolutional neural network fault identification method [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 299-307. (in Chinese)
- [16] 王婷. ZPW-2000A 无绝缘轨道电路故障预测研究[D]. 成都:西南交通大学,2015.
- [17] 中国铁路总公司. TG/XH 101—2015 普速铁路信号维护规则[S]. 北京:中国铁道出版社,2015.



**第一作者简介:**林俊亭,男,1978年8月生,博士、教授。主要研究方向为高速铁路列车运行控制系统故障诊断、列车安全间隔控制。曾发表《基于定性微分对策的列车碰撞防护方法》(《铁道学报》2021年第43卷第5期)等论文。  
E-mail: linjt@lzjtu.edu.cn