

DOI: 10.13382/j.jemi.B2306946

# 基于 DCNN 的 ZPW-2000A 无绝缘轨道电路 故障诊断研究\*

林俊亭 牛鹏远

(兰州交通大学自动化与电气工程学院 兰州 730070)

**摘要:**针对 ZPW-2000A 无绝缘轨道电路故障发生的多样性和不确定性导致的故障诊断效率低的问题,从故障特征提取和故障分类的角度出发,提出一种基于深度卷积神经网络(DCNN)的轨道电路故障诊断方法。通过故障分析总结出 12 种轨道电路故障状态,并将不同故障状态下的轨道电路监测数据进行标准化处理,作为 DCNN 模型的输入。模型采用卷积-池化结构提取轨道电路的关键特征并滤除冗余特征。BP 神经网络作为模型的全连接层,并结合 Softmax 函数进行故障分类。通过  $k$  折交叉验证法优化模型结构,确定最佳模型。实验结果表明,采用 4 层卷积-池化层结构的轨道电路故障诊断模型在诊断准确率方面达到了 98.48%,较同为最优模型的长短期记忆网络(LSTM)模型、深度前馈网络(DFN)模型、双向长短期记忆网络模型(BiLSTM)与 CNN-LSTM 组合模型分别提升了 6.06%, 6.06%, 3.33% 与 2.27%,训练收敛速度分别快了大约 1 250、4 250、1 250 与 1 450 次,且训练时的损失波动更小。本研究提升了轨道电路故障诊断效率,为轨道电路的故障诊断任务提供了一种新的有效方法。

**关键词:**无绝缘轨道电路;深度卷积神经网络;BP 神经网络; $k$  折交叉验证;故障诊断

**中图分类号:** TN83;U284.2 **文献标识码:** A **国家标准学科分类代码:** 580.3020

## Research on fault diagnosis of ZPW-2000A jointless track circuit based on DCNN

Lin Junting Niu Pengyuan

(School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

**Abstract:** Aiming at the low efficiency of fault diagnosis caused by the diversity and uncertainty of fault occurrence in the ZPW-2000A jointless track circuit, this paper proposes a deep convolutional neural network (DCNN)-based fault diagnosis method for jointless track circuit from the perspective of fault feature extraction and fault classification. Twelve rail circuit fault states are summarized through fault analysis, and the monitoring data of rail circuits under different fault states are standardized as inputs to the DCNN model. The model adopts the convolution-pooling structure to extract the key features of the rail circuit and filter out the redundant features. The back propagation neural network (BPNN) is used as the fully connected layer of the model and combined with the Softmax function for fault classification. The model structure is optimized by the  $k$ -fold cross-validation method to determine the best model. The experimental results show that the track circuit fault diagnosis model with a four-layer convolution-pooling layer structure achieves 98.48% in diagnosis accuracy, which is 6.06%, 6.06%, 3.33%, and 2.27% higher than the optimal models of long short-term memory (LSTM), deep feedforward network (DFN), bidirectional long and short-term memory (BiLSTM), and the combination of CNN-LSTM, respectively. Additionally, the training convergence speed is about 1 250, 4 250, 1 250, and 1 450 times faster, respectively, with less loss fluctuation during training. This study improves the efficiency of fault diagnosis of rail circuits and provides a new, effective method for the task of fault diagnosis of rail circuits.

**Keywords:** jointless track circuit; deep convolutional neural network; BP neural network;  $k$ -fold cross-validation; fault diagnosis

## 0 引言

无绝缘轨道电路系统的工作环境恶劣,易受到来自列车、天气等因素的信号干扰,这些干扰可能使得故障诊断过程中难以准确的识别故障信号,其复杂多样的故障模式如电阻性故障、短路、接地等都可能同时出现,使得诊断变得更加复杂。目前,现场通常采用定期维护维修的方式来排查轨道电路隐患,并依赖工作人员的经验进行故障诊断。然而,这种方式难以保证轨道电路故障诊断的实时性,诊断效率较低且极易出现诊断失误等问题<sup>[1]</sup>,从而会影响区间列车的正常运行。智能诊断系统将有助于更快速、更准确地排查隐患,为维修人员提供有价值的指导和支持,从而有效地缩短故障处理时间,提高区间列车的运行效率。在这种背景下,引入智能诊断算法以提高轨道电路系统故障的诊断效率和准确性是当前的轨道电路故障诊断研究热点<sup>[2]</sup>。

近年来,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[3]为解决轨道电路在稳态条件下诊断时效性不足的困境,用暂态理论将轨道电路设备状态分为多个类别,同时结合梅尔频率系数和动态时间规整模型实现轨道电路故障诊断。然而,该方法计算复杂度较高,尤其在大规模数据集上,需花费更多的计算资源和时间。文献[4]通过改进麻雀算法和 Q-learning 来优化诊断模型的结构、参数和权重提高集成学习的性能,从而提高轨道电路的故障诊断能力。但该方法的参数调整过程可能依旧是一个耗时的过程,且 Q-learning 可能在实际应用中需要精细的调整和稳定性处理,才能确保其收敛性和可靠性。文献[5]采用深度信念网络对轨道电路故障数据进行训练,提取高级故障特征,结合 BP 神经网络作为分类器,轨道电路的故障分类得以实现。但是该方法对于捕捉层次性特征的能力有限,对于多重特征提取方面的表现可能不够出色。文献[6]以 C4.5 决策树为基础,通过粗糙集属性约简方法实现了高效的轨道电路故障诊断。然而,决策树模型对数据质量非常敏感,如果数据中存在噪声、缺失值或不一致性,决策树性能可能受到负面影响。

深度卷积神经网络 (deep convolutional neural network, DCNN) 具有复杂度低、特征提取能力强以及参数共享等优点,对于非线性序列数据具有出色的处理能力<sup>[7]</sup>。其通过若干卷积层的滤波器学习特征,能够大规模处理监测数据且自动捕捉轨道电路监测数据中的关键信息,针对轨道电路监测数据呈现出的非线性特点,DCNN 能够出色的捕捉和建模这些非线性关系,相比传统方法更为灵活。文献[8]利用短时傅里叶变换得到滚动轴承振动时间序列的二维时频谱,输入深度卷积神经

网络提取不同的时频谱特征,完成了对轴承的故障诊断。文献[9]将时间卷积神经网络应用于模拟电路故障诊断领域,利用卷积网络的特征提取能力完成了对 4 阶 Butterworth 低通滤波器仿真电路的故障诊断。以上两种方法虽然充分的利用了卷积网络的特征提取能力,但对故障分类任务的研究并未精进。针对以上问题,以深度卷积神经网络为工具,嵌入到无绝缘轨道电路的故障诊断任务中。在多个卷积层和池化层的协同作用下,精准地提取故障所固有的特征,同时去除多余的信息噪声。此外,应用 BP 神经网络在分类任务中的卓越能力,将其作为深度卷积神经网络模型的全连接层,实现端到端的学习,以简化轨道电路的故障诊断流程,减少人工干预并提高诊断性能。

## 1 基于 DCNN 的轨道电路故障诊断方法

### 1.1 卷积神经网络

卷积神经网络是一种强大的机器学习工具,其基本结构通常包括输入层、卷积层、池化层、全连接层和输出层。深度卷积神经网络则若干卷积层、池化层与全连接层组成,能够有效地处理各种类型的数据<sup>[10]</sup>。卷积神经网络的结构如图 1 所示。

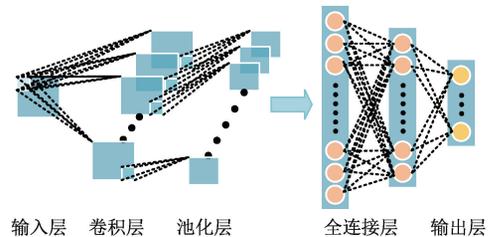


图 1 卷积神经网络结构

Fig. 1 Structure of convolutional neural network

### 1.2 特征提取

DCNN 对轨道电路特征提取过程分为卷积操作和下采样两个阶段。利用卷积层的滤波器<sup>[11]</sup> (也称为卷积核) 在输入网络后的轨道电路监测数据上滑动进行卷积操作,从而实现特征的提取。通过卷积操作可输出特征映射  $Z$ , 如式(1)所示。

$$Z_{i,l,k} = \sum V_{i,l,k} K_{i,j,m,n} \quad (1)$$

式中:  $V_{i,l,k}$  为输入数据,表示在通道  $i$  中第  $l$  行第  $k$  列的值。  $K_{i,j,m,n}$  为四维核张量,它代表了输出通道  $i$  中的一个单元与输入通道  $j$  中的一个单元之间的连接强度,同时还存在一个第  $m$  行和第  $n$  列的偏置项用于输出单元与输入单元之间。

下采样指利用池化层通过跳过核中的一些位置来降低计算的开销。例如只对输出的每个方向上的  $s$  个位置

进行采样,则输出  $\mathbf{Z}$  可表示为:

$$\mathbf{Z}_{i,l,k} = c(\mathbf{K}, \mathbf{V}, s)_{i,l,k} = \sum [V_{i,(l-1)s+m,(k-1)s+n}, \mathbf{K}_{i,j,m,n}] \quad (2)$$

式中:  $s$  为下采样卷积的步幅 (stride)。  $c(\mathbf{K}, \mathbf{V}, s)_{i,l,k}$  为下采样卷积函数。

采用 ReLU 函数作为其卷积层与池化层的激励函数,ReLU 函数的表达式如式(3)所示。

$$f_{\text{cov,pooling}}(\mathbf{Z}) = \max(0, \mathbf{Z}) \quad (3)$$

式中:  $f_{\text{cov,pooling}}(\cdot)$  为 ReLU 层的输出。

### 1.3 故障特征分类

利用 BP 神经网络完成轨道电路故障特征分类任务。将前面卷积层和池化层提取的特征进行整合并转换为一维向量,其中包含了数据的高级抽象表示。其隐藏层的输出  $\mathbf{Z}$  可表示为:

$$\mathbf{Z}_{h_j} = \sum_{i=1}^n (\mathbf{W}_{ij} \mathbf{X}_i) + b_j \quad (4)$$

式中:  $\mathbf{W}_{ij}$  表示第  $i$  个输入特征与第  $j$  个隐藏层节点之间的连接权重,  $\mathbf{X}_i$  表示输入层的第  $i$  个特征,  $b_j$  表示隐藏层第  $j$  个节点的偏差。输出层利用 Softmax 激活函数完成故障特征分类。

### 1.4 模型训练

DCNN 能够直接进行有监督学习训练<sup>[12]</sup>,这个过程包括前向传播和反向传播两个关键阶段。反向传播通过计算损失函数对网络中每个权重和偏置的梯度。假设损失函数为  $e(\mathbf{V}, \mathbf{K})$ , 在反向传播的过程中,首先需要求得损失函数对输出的偏导数,会收到一个张量  $\mathbf{G}$  如式(5)所示。

$$\mathbf{G}_{i,l,k} = \frac{\partial}{\partial \mathbf{Z}_{i,l,k}} e(\mathbf{V}, \mathbf{K}) \quad (5)$$

通过对核中的权重求导训练网络,可使用函数如式(6)所示。

$$g(\mathbf{G}, \mathbf{V}, s)_{i,j,m,n} = \frac{\partial}{\partial \mathbf{K}_{i,j,m,n}} e(\mathbf{V}, \mathbf{K}) = \sum \mathbf{G}_{i,m,n} V_{i,(l-1)s+m,(k-1)s+n} \quad (6)$$

在反向传播过程中,损失函数的梯度信息会传递回网络的不同层和神经元,以便调整权重和偏置,从而最小化总损失。这种梯度信息传递的方式是通过链式法则(chain rule, CR)来实现的<sup>[13]</sup>,通过不断迭代这个过程调整权重,以更好地拟合训练轨道电路监测数据,并提高在新数据上的泛化性能。

## 2 轨道电路故障类别分析

### 2.1 ZPW-2000A 无绝缘轨道电路基本原理

ZPW-2000A 型无绝缘轨道电路是一种在 UM71 轨道电路基础上结合我国国情进行创新的国产化无绝缘轨道电路,它能实现全程断轨监督检查,在我国得到了广泛应用。ZPW-2000A 型无绝缘轨道电路设备主要由室内及室外设备构成,其结构如图 2 所示。其中,室内设备有发送器、接收器、衰耗器、电缆模拟网络和轨道继电器等;室外设备有室外电缆、匹配变压器、调谐单元 BA1、调谐单元 BA2、空心线圈 SVA 和补偿电容等<sup>[1]</sup>。由发送器发送不同含义的低频信号,经两路分别沿主轨道与小轨道传入本区段接收器与运行方向前一区段接收器以驱动轨道继电器工作。其中,调谐区状态(XG、XGH)需送回本区段接收器,进而判断区段是否空闲。

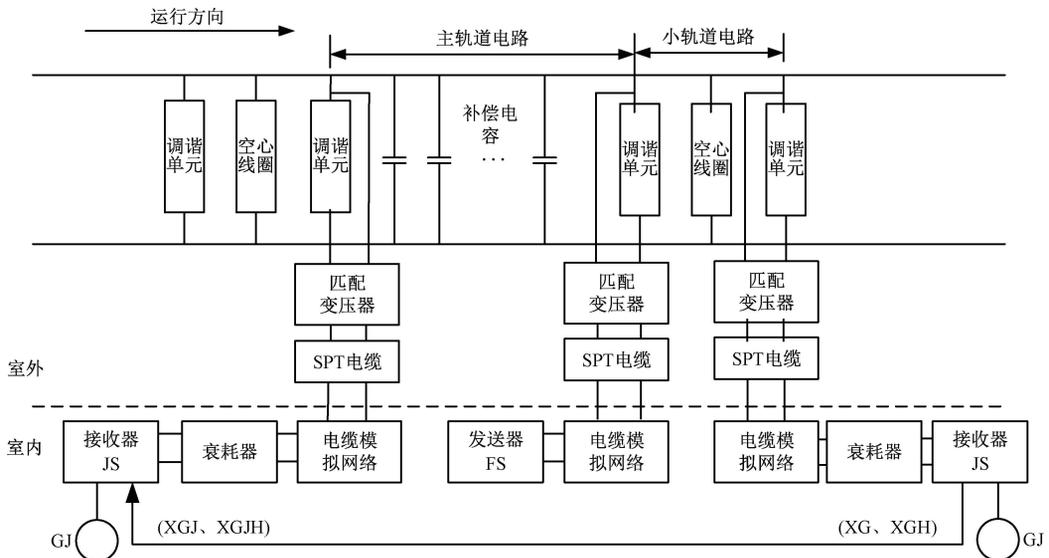


图 2 ZPW-2000A 无绝缘轨道电路结构

Fig. 2 Structure of ZPW-2000A jointless track circuit

### 2.2 故障类别分析

在实际的轨道电路应用中,轨道电路元器件的性能退化所引发的故障以及与之相伴而来的元器件连接问题呈现出的影响是一致的<sup>[14]</sup>。比如,不论是补偿电容容值变化故障,还是连接方面的故障,最终都能归结为连接阻抗升高的形式。本文根据 ZPW-2000A 无绝缘轨道电路的结构与工作原理,通过改变各元器件连接阻抗来模拟各种故障类别。在实际情况中,轨道电路的匹配变压器与相邻调谐单元安装在同一模块箱中,故本文将两者连接故障归为一类。则轨道电路故障类别如表 1 所示。

表 1 轨道电路故障类别

Table 1 Track circuit fault categories

故障代码	故障名称	备注
F1	正常状态	正常
F2	发送设备连接故障	室内发送端
F3	发送端模拟网络连接故障	
F4	发送端 BA1 连接故障	
F5	发送端 SVA 连接故障	室外发送端
F6	发送端 BA2 连接故障	
F7	接收端 BA1 连接故障	
F8	接收端 SVA 连接故障	室外接收端
F9	接收端 BA2 连接故障	
F10	接收端模拟网络连接故障	
F11	接收设备连接故障	室内接收端
F12	补偿电容连接故障	钢轨线路

### 3 基于 DCNN 的无绝缘轨道电路模型设计

#### 3.1 故障数据获取

由于真实的轨道电路故障数据难以获取,本文通过兰州交通大学轨道电路仿真实验平台进行仿真实验从而

获取轨道电路故障数据,仿真参数如表 2 所示<sup>[14]</sup>。ZPW-2000A 轨道电路实验平台如图 3 所示。

表 2 轨道电路实验平台仿真参数

Table 2 Parameters related to track circuit test platform

载频/Hz	传输电缆 长度/m	钢轨线路 长度/m	道砟电阻/ ( $\Omega \cdot \text{km}$ )	发送端输出 电平级	匹配变压器 变比	补偿电容		
						数量	间距/m	容值/ $\mu\text{F}$
2 600	7 500	960	3	1	1 : 9	12	80	40



图 3 ZPW-2000A 轨道电路实验平台

Fig. 3 ZPW-2000A track circuit experiment platform

根据表 1 所示故障类型 F1~F12,共测得轨道电路故障数据 12 组,每组故障模式 110 条,共计 1 320 条数据。铁路运营管理部门建成的轨道电路信号集中监测系统可对一段轨道电路的多个节点处进行电压或电流的测量,本文根据现场情况共设定 12 个监测量,依次为发送端电压 C1、发送端电流 C2、移频电缆侧发送电压 C3、发送端 BA1 电流 C4、发送端 SVA 电流 C5、发送端 BA2 电流 C6、接收端 BA1 电流 C7、接收端 SVA 电流 C8、接收端 BA2 电流 C9、移频电缆测接收电压 C10、移频主轨入电压 C11 和移频主轨接收电压 C12。表 3 为某铁路局提供的室内真实监测数据与实验平台仿真数据对比。由表 3 可知,仿真数据与室内真实监测数据的最大相对误差仅 2.90%。表明轨道电路实验平台具有高度准确性,可准确描述信号集中监测系统各监测点的电压和电流模式。

#### 3.2 故障诊断网络结构

以 3.1 节中的 12 个轨道电路电压、电流监测量 C1~

表 3 室内真实监测数据与实验平台数据对比

Table 3 Comparison of real indoor monitoring data and test platform data

检测参量	C1/V	C2/A	C3/V	C10/V	C11/V	C12/V
检测值	136.000	0.275	76.450	5.812	0.894	0.703
仿真值	136.000	0.267	78.156	5.792	0.873	0.689
绝对误差	0.000	0.008	-1.706	0.02	0.021	0.014
相对误差	0.00%	2.90%	-2.23%	0.34%	2.34%	1.99%

C12 分别作为基于深度卷积神经网络的轨道电路故障诊断模型输入层的 12 个输入量。卷积层、池化层激励函数均采用 ReLU 函数,由于采集到的故障数据大都为非线性数据,ReLU 函数的非线性特性能够使网络展现出更强大的表示能力<sup>[15]</sup>。池化层采用最大池化(max-pooling)进行下采样以保留重要特征。全连接层采用 BP 神经网络进行训练,训练过程中,BP 算法利用误差的反向传播,逐渐调整各层之间的权重参数,使得网络的输出能够更

好地拟合训练数据。这个过程迭代进行直到网络的输出与真实标签之间的误差足够小或达到预定的训练轮数为止。由于深度学习极易造成过拟合的现象,故本文在全连接层之后添加 Dropout 正则化层用于防止网络模型的过拟合现象<sup>[16]</sup>,提升网络的泛化能力。输出层则分别对应 2.2 节中的 F1~F12 故障类别,并由 softmax 函数完成故障分类。基于深度卷积神经网络的 ZPW-2000A 型无绝缘轨道电路故障诊断网络结构如图 4 所示。

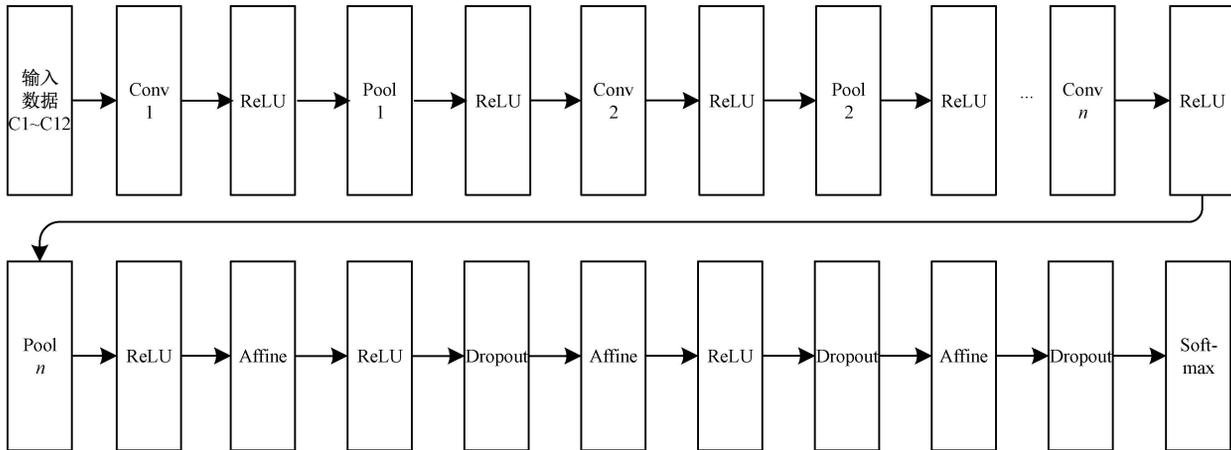


图 4 轨道电路故障诊断网络结构

Fig. 4 Structure of track circuit fault diagnosis network

### 3.3 实验过程

在训练网络模型之前,要对样本数据进行标准差标准化处理,使得每个样本的不同特征具有相同的尺度,有助于加快模型的收敛速度;再者可以避免反向传播时出现梯度消失或梯度爆炸的问题。在标准差标准化之前,首先需要计算每个样本的均值与标准差。假设有  $n$  个样本,每个样本的特征值为  $x_1, x_2, \dots, x_n$ ,则样本均值  $\mu$  如式(7)所示。

$$\mu = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (7)$$

样本标准差  $\sigma$  如式(8)所示。

$$\sigma = \sqrt{\frac{(x_1 - \mu)^2 + (x_2 - \mu)^2 + \dots + (x_n - \mu)^2}{n}} \quad (8)$$

则第  $n$  个样本进行标准差标准化后的特征值  $\tilde{x}_n$  如式(9)所示。

$$\tilde{x}_n = \frac{x_n - \mu}{\sigma} \quad (9)$$

ZPW-2000A 轨道电路故障诊断流程如图 5 所示。

基于深度卷积神经网络的 ZPW-2000A 轨道电路故障诊断具体流程如下:

步骤 1) 监测并提取轨道电路仿真平台运行数据,对

包括正常和故障数据进行数据标准差标准化预处理,并将数据集分为训练集和测试集。

步骤 2) 构建深度卷积神经网络模型。将标准化后的训练集输入到卷积层和池化层,以提取轨道电路故障特征并滤除冗余信息。在反向传播过程中,运用链式法则计算损失函数对卷积层权重和偏置的梯度,并利用这些梯度来更新网络层参数。

步骤 3) 将最后一层池化层的输出作为 BP 神经网络的输入,输出层使用 Softmax 激活函数对故障进行分类。

步骤 4) 在确定模型参数后,使用测试集评估轨道电路故障诊断模型的性能,并输出诊断结果。

## 4 仿真试验

### 4.1 DCNN 模型最优参数确认

为了得到最优的故障诊断分类模型,本文结合  $k$  折交叉验证法,对 6 层以下不同卷积-池化结构的 DCNN 模型进行了深入研究。为此,建立了 6 个不同卷积-池化层数的 DCNN 模型,分别标记为 model\_1~model\_6。在进行实验时,采用 6 折交叉验证,将训练集随机分为 6 个互斥的折叠,并进行了 6 次预训练。每次预训练都保留一个折叠作为验证集,以验证模型参数的性能。这种  $k$  折交叉验证的方法能够有效地评估模型在不同数据集上

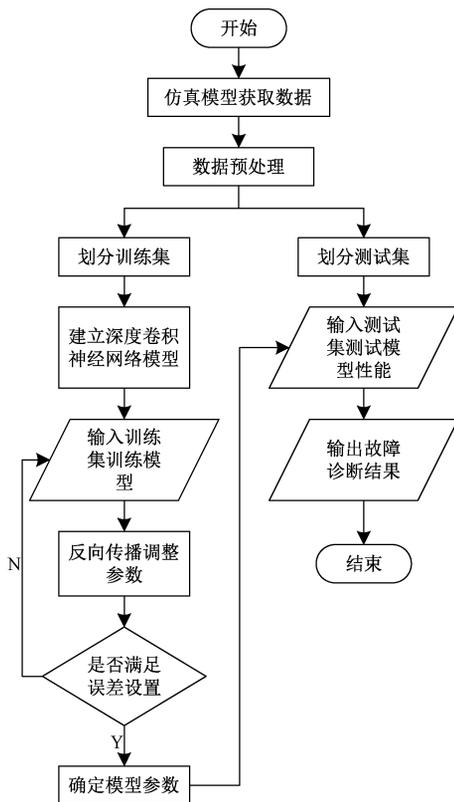


图 5 轨道电路故障诊断流程

Fig. 5 Flowchart of track circuit fault diagnosis

的表现,提高实验结果的可信度和稳健性,方法原理如图 6 所示。



图 6 6 折交叉验证

Fig. 6 6-fold cross validation

经过对 model\_1 ~ model\_6 进行 6 折交叉验证,实验结果如图 7 所示。可以发现:当模型采用 1 层卷积-池化结构时,虽然故障类别识别准确率较为可观,但每一折验证集的识别效果波动较大,表现不够稳定。随着层数逐渐增加到 4 层,不但平均识别准确率逐渐增强并且每一折验证集的识别效果趋于稳定,这意味着随着模型复杂

度的增加,故障识别能力和泛化能力也逐步提升,证明了深度卷积神经网络对轨道电路进行故障诊断的可行性。然而,当层数增加到 5 层之后,识别效果降低且发生较严重波动,出现了过拟合现象,导致识别率和识别稳定性严重下降。

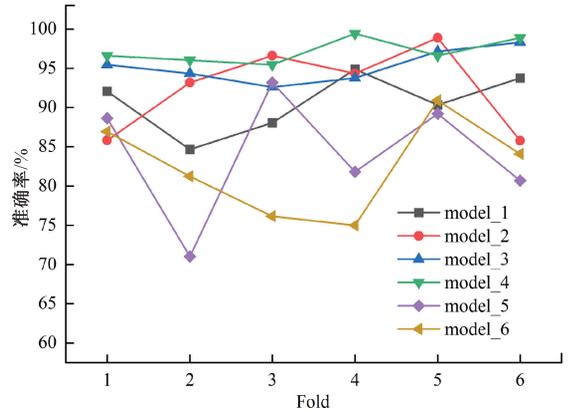


图 7 各模型 6 折交叉验证准确率

Fig. 7 Accuracy of 6-fold cross-validation for each model

综上,可以得出基于深度卷积神经网络的 ZPW-2000A 轨道电路故障诊断模型最佳的卷积-池化结构为 4 层。该结构在故障类别识别率上取得了良好表现,同时保持了较好的识别稳定性和泛化能力。各模型每次预训练后每一折验证集识别准确率如表 4 所示。

表 4 各模型预训练准确率具体值

Table 4 Specific values of pre-training accuracy for each model

模型	准确率/%						平均准确率/%
	fold1	fold2	fold3	fold4	fold5	fold6	
model_1	92.05	84.66	88.07	94.89	90.34	93.75	90.625
model_2	85.8	93.18	96.59	94.32	98.86	85.79	92.424
model_3	95.45	94.32	92.61	93.75	97.16	98.3	95.265
model_4	96.59	96.02	95.45	99.43	96.59	98.86	97.159
model_5	88.63	71.02	93.18	81.82	89.2	80.68	84.091
model_6	86.93	81.25	76.14	0.75	90.91	84.09	82.386

针对不同的卷积神经网络模型,需要选择不同的优化器,常用的优化方法有自适应矩估计(Adam)、均方根传播(RMSprop)、随机梯度下降(SGD)、自适应增量(AdaDelta)<sup>[17]</sup>等。最佳卷积-池化结构确定为 4 层之后,分别对以上 4 种常见的优化器做了对比试验,实验结果表明,在以上 4 种优化器算法中,Adam 优化器表现出更快的收敛速度和更好的稳定性,且故障分类的准确率最高,具有更佳的性能。

#### 4.2 故障识别结果

将故障训练集输入到 4.1 节确认的模型中进行再训

练,同时输入测试集测试模型性能。训练过程中采用了 Adam 自适应优化器,学习率设置为 0.001, Batch\_Size 为 256, 迭代 1 000 次。整个迭代过程如图 8 所示。从图中可以明显看出,在迭代次数达到 250 次左右后,训练集和

测试集的损失值和准确率都趋于收敛,且损失值最低达到了 0.025 8, 准确率达到了 98.48%。这说明基于深度卷积神经网络的轨道电路故障诊断模型在故障类别分类方面表现出了优良的效果。

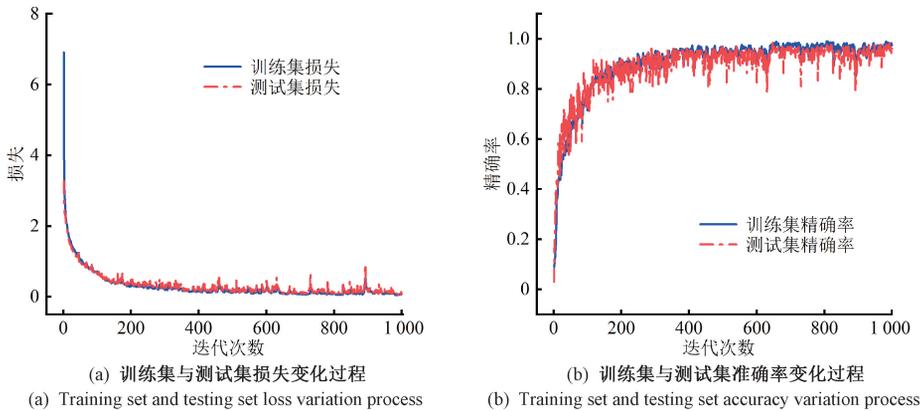


图 8 训练集与测试集迭代过程

Fig. 8 Training set and testing set iteration process

将测试集输入分类模型后得到的测试结果如图 9 所示,在 264 条测试样本中,仅 4 条样本被错误分类为其他故障:一条 F4 故障样本被错误分类为 F6 故障,两条 F7 故障样本被错误分类为 F8 故障,一条 F12 故障样本被错误分类为 F3 故障。然而,对于 F1、F2、F3、F5、F6、F8、F9、F10、F11 故障,分类模型均取得了 100% 正确的分类结果,验证了模型的可行性。

与参数调优,以确保它们的性能最佳化。由于不同模型之间训练收敛速度有所差异,所以各种模型的迭代次数设置有所不同。4 种模型的准确率与最低损失值如表 5 所示。

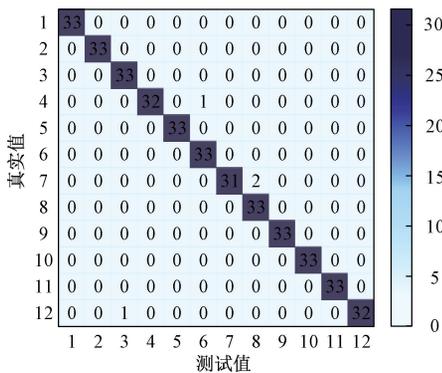


图 9 测试结果的混淆矩阵

Fig. 9 Confusion matrix of test results

### 4.3 方法对比

为进一步验证深度卷积神经网络的优越性,将深度卷积神经网络与两种基线模型长短时记忆网络(long short-term memory, LSTM)<sup>[18]</sup>和深度前馈网络(deep feedforward neural network, DFN)<sup>[19]</sup>以及 LSTM 的改进模型 BiLSTM 与组合模型 CNN-LSTM 对无绝缘轨道电路故障分类的性能影响,为此将通过准确率值与损失值来可视化这些比较。4 种模型均进行了详细的实验

表 5 各模型准确率与损失值对比

Table 5 Comparison of accuracy and loss values for each model

模型	准确率/%	损失值	收敛速度/次
DCNN	98.48	0.025 8	250
LSTM	92.42	0.134 5	1 500
DFN	92.42	0.186 1	4 500
BiLSTM	95.15	0.069 1	1 500
CNN-LSTM	96.21	0.057 0	1 700

由表 5 可知,DCNN 模型较 LSTM 模型、DFN 模型 BiLSTM 模型以及 CNN-LSTM 组合模型的诊断准确率分别高出 6.06%、6.06%、3.33% 与 2.27%,且损失值明显低于 4 种对比模型。各对比模型训练过程中的准确率变化如图 10 所示。

各对比模型训练过程中的损失值变化如图 11 所示。对于 LSTM 方法,迭代约 1 500 次后损失值趋于收敛,且训练过程波动明显,这表明该模型训练稳定性不足。对于 DFN 方法,虽训练过程稳定,但收敛速度缓慢,迭代约 4 500 次后才显示出收敛趋势,表明该模型需要更多的迭代次数才能达到收敛状态。BiLSTM 模型与 CNN-LSTM 组合模型较 LSTM 模型的收敛速度接近,但能更好的适应轨道电路数据,其准确率与损失值的表现都优于 LSTM,但是训练过程中损失曲线波动更明显,呈现出更

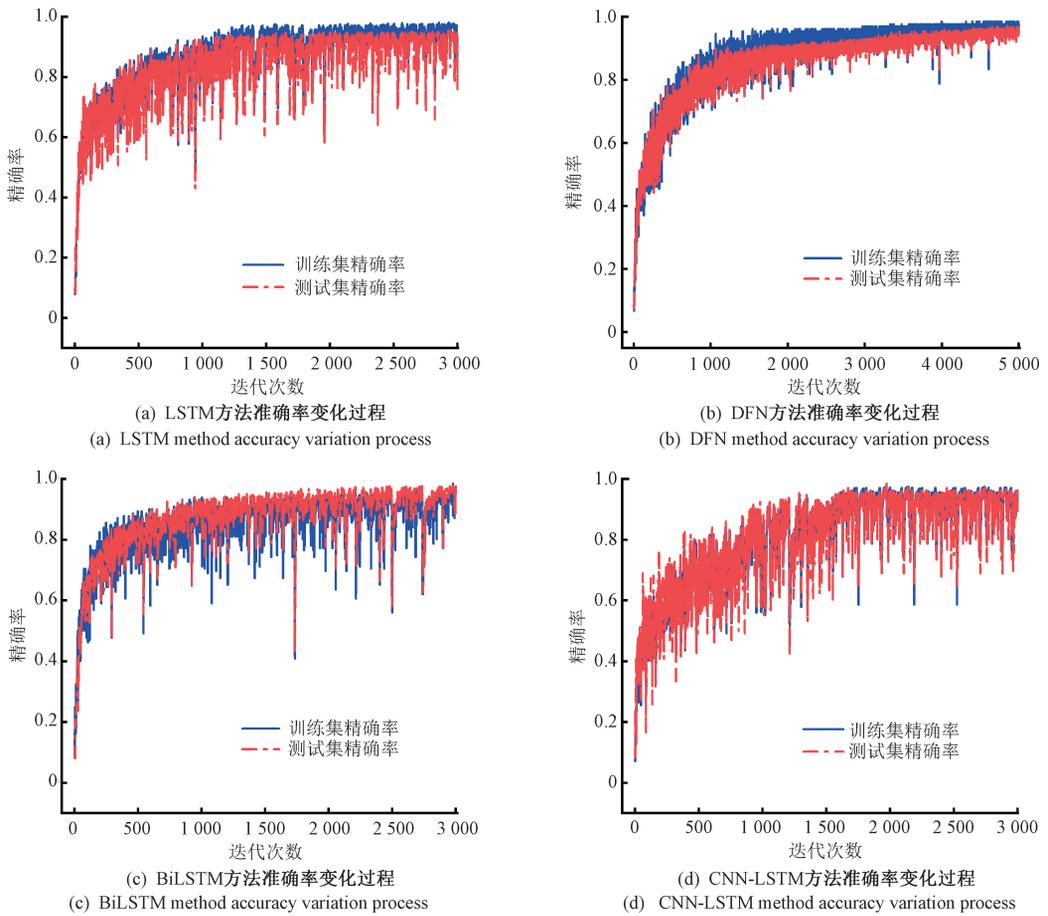


图 10 不同模型的准确率变化过程

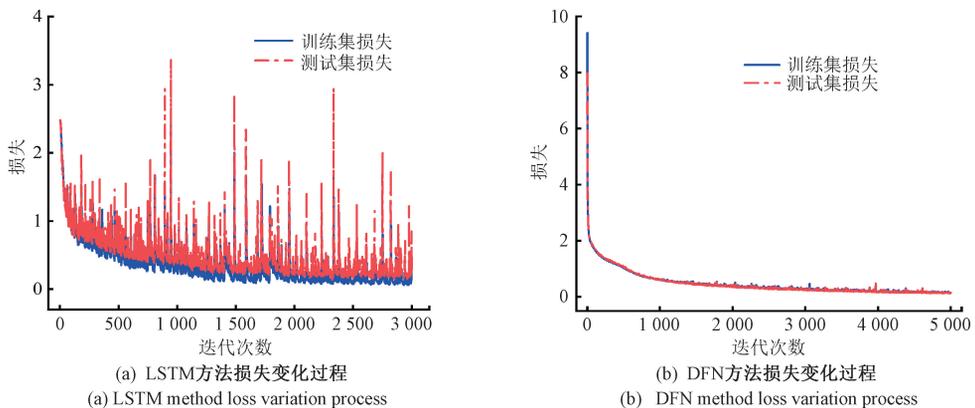
Fig. 10 Different models' precision evolution

差的稳定性。相比之下,DCNN 的损失值在训练过程中迅速下降,收敛速度更快,最终达到了更低的损失值。

综上,深度卷积神经网络在无绝缘轨道电路故障分类任务中表现出更好的性能,具有更高的准确率和更快的收敛速度。这进一步表明了 DCNN 在处理轨道电路数据时的优势,并强调了其在实际应用中的潜力。

### 5 结 论

本文基于深度卷积神经网络(DCNN)提出了一种高效的无绝缘轨道电路故障诊断方法。在特征提取方面,通过使用多层卷积-池化层结构,有效提取了轨道电路监测数据中的关键特征,同时去除了冗余信息。在故障分



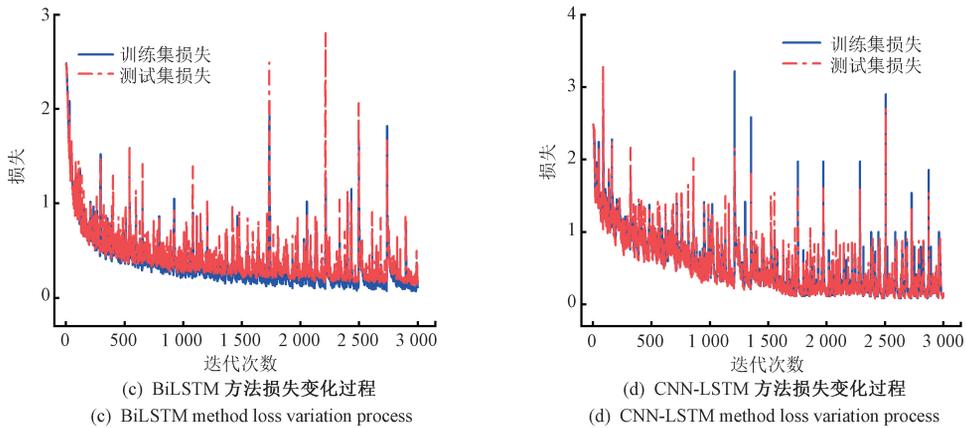


图 11 不同模型的损失变化过程

Fig. 11 Different models' loss evolution

类方面,利用 BP 神经网络并结合 Softmax 函数完成了故障分类。通过与其他模型如 LSTM、BiLSTM、DFN 以及组合模型 CNN-LSTM 相比较,DCNN 模型在故障诊断准确率、训练收敛速度和稳定性方面展现了明显优势。实验结果显示,DCNN 模型在故障分类准确率上达到了 98.48%,明显高于其他模型,并且训练过程中损失值较低,表现出最佳的泛化能力。本研究突显了 DCNN 在处理轨道电路非线性序列数据方面的强大能力,模型不仅提高了故障诊断的效率,也减少了人工干预,为未来轨道电路故障诊断技术的发展提供了新的方向。未来工作将进一步优化模型结构和参数,探索更多种类的故障模式与故障数据,以提高模型的适用性和诊断范围,进一步推动智能诊断系统的实用化和智能化。

### 参考文献

- [ 1 ] 覃定明. ZPW-2000A 信号设备故障诊断专家系统研究[D]. 北京:北京交通大学, 2009.  
QIN D M. Research on ZPW-2000A signal equipment fault diagnosis expert system [ D ]. Beijing: Beijing Jiaotong University, 2009.
- [ 2 ] 林俊亭,王帅. 基于 DBN-MPA-LSSVM 的无绝缘轨道电路故障诊断研究[J]. 电子测量与仪器学报, 2022, 36(9): 37-44.  
LIN J T, WANG SH. Research on fault diagnosis of jointless track circuit based on DBN-MPA-LSSVM [ J ]. Journal of Electronic Measurement and Instrumentation, 2022, 36(9): 37-44.
- [ 3 ] 杨璟,王小敏,张文芳,等. 基于 PMFCC-DTW 的轨道电路暂态故障诊断[J]. 铁道学报, 2021, 43(5): 104-111.  
YANG J, WANG X M, ZHANG W F, et al. Transient fault diagnosis of track circuit based on PMFCC-DTW [ J ]. Journal of the China Railway Society, 2021, 43(5):

104-111.

- [ 4 ] 徐凯,郑浩,涂永超,等. 改进麻雀算法和 Q-Learning 优化集成学习轨道电路故障诊断[J]. 铁道科学与工程学报, 2023, 20(11): 4426-4437.  
XU K, ZHENG H, TU Y CH, et al. Research on fault diagnosis of track circuit based on improved sparrow search algorithm and Q-Learning optimization for ensemble learning [ J ]. Journal of Railway Science and Engineering, 2023, 20(11): 4426-4437.
- [ 5 ] 谢旭旭,戴胜华. 基于深度学习的无绝缘轨道电路故障诊断研究[J]. 铁道学报, 2020, 42(6): 79-85.  
XIE X X, DAI SH H. Research on fault diagnosis of uninsulated track circuits based on deep learning [ J ]. Journal of the China Railway Society, 2020, 42(6): 79-85.
- [ 6 ] 朱文博,王小敏. 基于组合决策树的无绝缘轨道电路故障诊断方法研究[J]. 铁道学报, 2018, 40(7): 74-79.  
ZHU W B, WANG X M. Research on fault diagnosis method of uninsulated track circuit based on combined decision tree [ J ] Journal of the China Railway Society, 2018, 40(7): 74-79.
- [ 7 ] 蓝金辉,王迪,申小盼. 卷积神经网络在视觉图像检测的研究进展[J]. 仪器仪表学报, 2020, 41(4): 167-182.  
LAN J H, WANG D, SHEN X P. Research progress on visual image detection based on convolutional neural network [ J ]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167-182.
- [ 8 ] 唐波,陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 88-93.  
TANG B, CHEN SH SH. Method of bearing fault diagnosis based on deep convolutional neural network [ J ]. Journal of

- Electronic Measurement and Instrumentation, 2020, 34(3): 88-93.
- [ 9 ] 阳景,潘强,潘红兵. 基于时间卷积网络的模拟电路故障诊断方法 [J]. 电子测量技术, 2019, 42 ( 5 ): 128-132.
- YANG J, PAN Q, PAN H B. Fault diagnosis method of analog circuits based on temporal CNN [J]. Electronic Measurement Technology, 2019, 42(5): 128-132.
- [ 10 ] 陈星. 基于卷积神经网络算法的飞机发电机故障诊断研究 [J]. 国外电子测量技术, 2020, 39(11): 57-60.
- CHEN X. Fault diagnosis of aircraft generator based on convolution neural network algorithm [J]. Foreign Electronic Measurement Technology, 2020, 39 ( 11 ): 57-60.
- [ 11 ] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to documenter cognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [ 12 ] BENGIO Y. Learning deep architectures for AI [J]. Foundations and Trends® in Machine Learning, 2009, 2(1): 1-127.
- [ 13 ] ZHANG CH Y, BENGIO S, HARDT M, et al. Understanding deep learning (still) requires rethinking generalization [J]. Communications of the ACM, 2021, 64(3): 107-115.
- [ 14 ] 孙上鹏. 无绝缘轨道电路故障诊断方法研究 [D]. 北京: 北京交通大学, 2014.
- SUN SH P. Research on fault diagnosis for railway jointless track circuits [D]. Beijing: Beijing Jiaotong University, 2014.
- [ 15 ] DAUBECHIES I, DEVORE R, FOUCART S, et al. Nonlinear approximation and (deep) ReLU networks [J]. Constructive Approximation, 2022, 55(1): 127-172.
- [ 16 ] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [ 17 ] ZHAO J D, GAO Y, YANG ZH ZH, et al. Truck traffic

speed prediction under non-recurrent congestion; Based on optimized deep learning algorithms and GPS data [J]. IEEE Access, 2019, 7(1): 9116-9127.

- [ 18 ] GRAVES A. Long short-term memory [J]. Supervised Sequence Labelling with Recurrent Neural Networks, 2012, 385(1): 37-45.
- [ 19 ] CHUMACHENKO K, IOSIFIDIS A, GABBOUJ M. Feedforward neural networks initialization based on discriminant learning [J]. Neural Networks, 2022, 146(2): 220-229.

## 作者简介



林俊亭(通信作者), 2001 年于兰州交通大学获得学士学位, 2008 年于北京交通大学获得硕士学位, 2018 年于兰州交通大学获得博士学位, 现为兰州交通大学自动化与电气工程学院教授, 主要研究方向为轨道交通列车智能控制与自主运行技术、RAMS 分析及智能运维。

E-mail: linjt@lztu.edu.cn

**Lin Junting** (Corresponding author) received his B. Sc. degree from Lanzhou Jiaotong University in 2001, M. Sc. degree from Beijing Jiaotong University in 2008 and Ph. D. degree from Lanzhou Jiaotong University in 2018, respectively. Now he is a professor in Lanzhou Jiaotong University. His main research interests include intelligent control and autonomous operation technology of rail transit trains, RAMS analysis and intelligent maintenance.



牛鹏远, 2022 年于兰州交通大学获得学士学位, 现为兰州交通大学自动化与电气工程学院在读研究生, 主要研究方向为轨道电路故障诊断。

E-mail: 657551486@qq.com

**Niu Pengyuan** received his B. Sc. degree in 2022 from Lanzhou Jiaotong University. Now he is a M. Sc. candidate in School of Automation and Electrical Engineering, Lanzhou Jiaotong University. His main research interest includes fault diagnosis of track circuit.