

DOI: 10.13382/j.jemi.B2306818

# 基于智能优化深度网络的轨道电路故障诊断研究\*

彭菲桐<sup>1</sup> 徐 凯<sup>1</sup> 吴仕勋<sup>1</sup> 黄德青<sup>2</sup>

(1. 重庆交通大学信息科学与工程学院 重庆 400074; 2. 西南交通大学电气工程学院 成都 610031)

**摘要:**针对无绝缘轨道电路故障的随机性和复杂性,采用单一诊断模型存在提取特征片面,且模型结构经验设计不合理的问题,提出一种智能优化深度网络的故障诊断方法。首先以轨道电路信号集中监测系统的6个电压检测量建立故障特征集,使用卷积神经网络(CNN)提取特征空间信息,长短期记忆网络(LSTM)提取时间特征信息,从而让轨道电路故障诊断所提取的特征兼具时空信息;同时,引入遗传算法(GA)优化上述深度神经网络的结构及参数,并结合强化学习中的Q-learning方法对两个组合网络特征级的输出权重进一步优化;最后,使用多层感知器(MLP)对深度网络的分类误差进行拟合修正,提高模型对轨道电路的故障诊断精度。仿真结果表明,利用智能优化的深度网络模型对轨道电路的故障诊断相较于单一模型、精炼设计的组合模型识别率可达99.28%,评价指标等均有所提升,具有更高的故障诊断准确度,证明了智能优化深度网络能进一步提高轨道电路的故障诊断性能。

**关键词:** 轨道电路故障诊断;卷积神经网络;长短期记忆网络;遗传算法;Q-learning

**中图分类号:** TN801 **文献标识码:** A **国家标准学科分类代码:** 580.30

## Research on fault diagnosis of track circuit based on intelligent optimization deep network

Peng Feitong<sup>1</sup> Xu Kai<sup>1</sup> Wu Shixun<sup>1</sup> Huang Deqing<sup>2</sup>

(1. School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China;

2. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

**Abstract:** Aiming at the randomness and complexity of jointless track circuit faults, the single diagnosis model has the problems of one-sided extraction features and unreasonable empirical design of model structure. A fault diagnosis method based on intelligent optimization deep network is proposed. Firstly, the fault feature set is established by six voltage detection quantities of the track circuit signal centralized monitoring system. The convolutional neural network (CNN) is used to extract the feature space information, and the long short-term memory network (LSTM) is used to extract the time feature information, so that the features extracted by track circuit fault diagnosis have both spatial and temporal information. At the same time, the genetic algorithm (GA) is introduced to optimize the structure and parameters of the aforementioned deep neural network, and the output weight of the feature level of the two combined networks is further optimized by combining the Q-learning method in reinforcement learning. Finally, the multi-layer perceptron (MLP) is used to fit and correct the classification error of the deep network to improve the fault diagnosis accuracy of the model for the track circuit. The simulation results show that the recognition rate of the fault diagnosis of the track circuit using the intelligent optimized deep network model can reach 99.28% compared with the single model and the refined design combination model. The evaluation index is improved, and the fault diagnosis accuracy is higher. It is proved that the intelligent optimized deep network can further improve the fault diagnosis performance of the track circuit.

**Keywords:** fault diagnosis; jointless track circuit; convolutional neural networks; LSTM network; genetic algorithm; Q-learning

## 0 引言

轨道电路是铁路信号系统的重要设备,及时精准地诊断轨道电路故障,直接影响铁路的运输效率和行车安全。目前,ZPW-2000A 轨道电路一旦发生故障,现场技术人员主要利用移频测试表对衰耗器、电缆模拟网络盘及电缆上数据进行测试,或利用微机监测测试各部位数据,最后根据这些数据对故障进行处理<sup>[1]</sup>,此诊断方法事倍功半,很难达到故障状态修和准确修的要求。为了提高铁路信号系统的设备维修水平,先后研制了 TJWX-I 型和 TJWX-2000 型微机监测系统,如今发展到 CSM 信号集中监测系统,实现了对轨道电路设备状态的实时监测,但由于系统缺乏完善的状态监测与故障诊断于一体的功能。因此,引入智能算法结合信号集中监测系统监测值提升对轨道电路的故障诊断效果具有重要意义。

近年来,使用人工智能方法分析监测数据与故障之间的映射关系进行故障诊断成为了研究方向,并取得了许多成果。文献[2]利用粗糙集理论结合组合决策树对故障进行逐级诊断。文献[3]以模拟退火算法实现了对轨道电路的故障诊断。文献[4]提出遗传算法对轨道电路补偿电容及道砟电阻的故障进行判别。文献[5]建立最小二乘支持向量机的故障诊断方法,与 BP 神经网络故障诊断方法比较,诊断正确率提高 17.14%,运算时间减少 2/3。文献[6]以模糊神经网络为模型进行故障诊断,通过对样本数据的训练,采用一阶梯度寻优算法对模型参数进行了优化。文献[7]运用深度信念网络实现了轨道电路的故障分类,运用深度信念网络的无监督学习对故障数据进行训练,得到最优参数值并提取出故障数据高层的分布式特征。文献[8]使用卷积神经网络实现了轨道电路调谐区的故障诊断。文献[9]针对单一方法存在不足,根据模糊故障诊断法、遗传算法和灰色系统理论建立组合模型实现了故障诊断,并验证组合模型具有更高的准确度。文献[10]针对传统 BP 网络的缺点,引入蝙蝠算法优化 BP 网络参数,提高诊断精度与网络收敛速度。文献[11]引入粒子群算法,优化支持向量机参数,得到了更优的参数结构,故障诊断准确率高于普通模型。文献[12]将模拟退火算法与和粒子群最小二乘支持向量机相结合,以模拟退火优化粒子群算法,在优化最小二乘支持向量机参数,得到了更高的故障诊断准确率。文献[13]利用遗传算法优化粒子群结构,进而搜索深度信念网络网络结构参数,使模型具有更高的故障诊断准确率。文献[14]利用深度置信网络提取出多维度特征向量作为输入,采用海洋捕食者算法优化最小二乘支持向量机的参数,从而对模型进行故障诊断。

上述模型在轨道电路故障诊断领域取得了较好的效

果,但诊断模型的性能还能有进一步的提升。文献[2-5]使用传统机器学习的方法进行故障诊断,使得模型诊断准确率不稳定且诊断结果缺乏可解释性<sup>[15]</sup>;文献[6-9]运用了深度网络模型或组合模型进行故障诊断,但诊断模型较为单一且在模型结构参数的设定上过于主观,缺少合理性。文献[10]使用组合模型进行故障诊断,各模型使用传统机器学习方法且在组合模型内部结构参数设定上不够合理;文献[11-14]使用智能算法优化网络参数进行故障诊断,但主要诊断模型仍是单一模型,其诊断存在不足。引入组合预测方法可以减少由参数或模型错误导致的预测误差,甚至在单项预测结果存在有偏性的情况下,通过组合能产生具有无偏性的预测结果。因此,将不同预测模型进行有效组合,可以视为对真实数据生成过程的有效补充<sup>[16]</sup>。

在决策级参数优化中,与传统的机器学习方法相比,强化学习可以根据环境的反馈来自动调整权重,自动学习最佳策略和权重,以使系统能够学习并适应不同的场景和任务。在监督学习中,通常需要大量的标签数据来训练模型,而在强化学习中,只需要定义环境的奖励函数,系统可以通过与环境的交互来学习最佳权重。强化学习可以根据环境的变化自动调整权重,从而适应不同的任务和场景。它能够学习到一种策略,使得系统在不同情况下都能够取得最大的奖励。同时,它也会利用已有的知识和经验来最大化累积奖励。

针对以上问题,本文结合深度网络和强化学习完成以下工作:1)提出一种卷积神经网络结合长短期记忆神经网络并行提取时空信息的组合模型进行轨道电路的故障诊断;2)在组合模型的基础之上,利用遗传算法优化组合网络结构及参数,同时借助强化学习中的 Q-learning 优化组合网络的决策级权值参数,通过具有探索性的学习过程,尝试新的行动以发现更好的参数组合;3)最后使用多层感知器 MLP 对优化后的组合网络分类结果与真实结果对比修正,从而建立了充分提取数据特征且网络结构设定合理的轨道电路故障诊断模型,通过实验验证了所提模型的优越性。

## 1 智能优化深度网络模型

智能优化深度网络模型框架如图 1 所示。

该框架分为 4 个部分进行,包括仿真轨道电路获取故障数据集,GA 算法优化组合网络模型结构及参数,强化学习 Q-learning 优化组合网络权重,最后使用多层感知器拟合组合网络误差修正故障诊断结果。

第 1 步根据轨道电路电路情况建立仿真模型,获取故障数据集,在进行归一化等数据预处理操作后将数据集分为训练集和测试集。

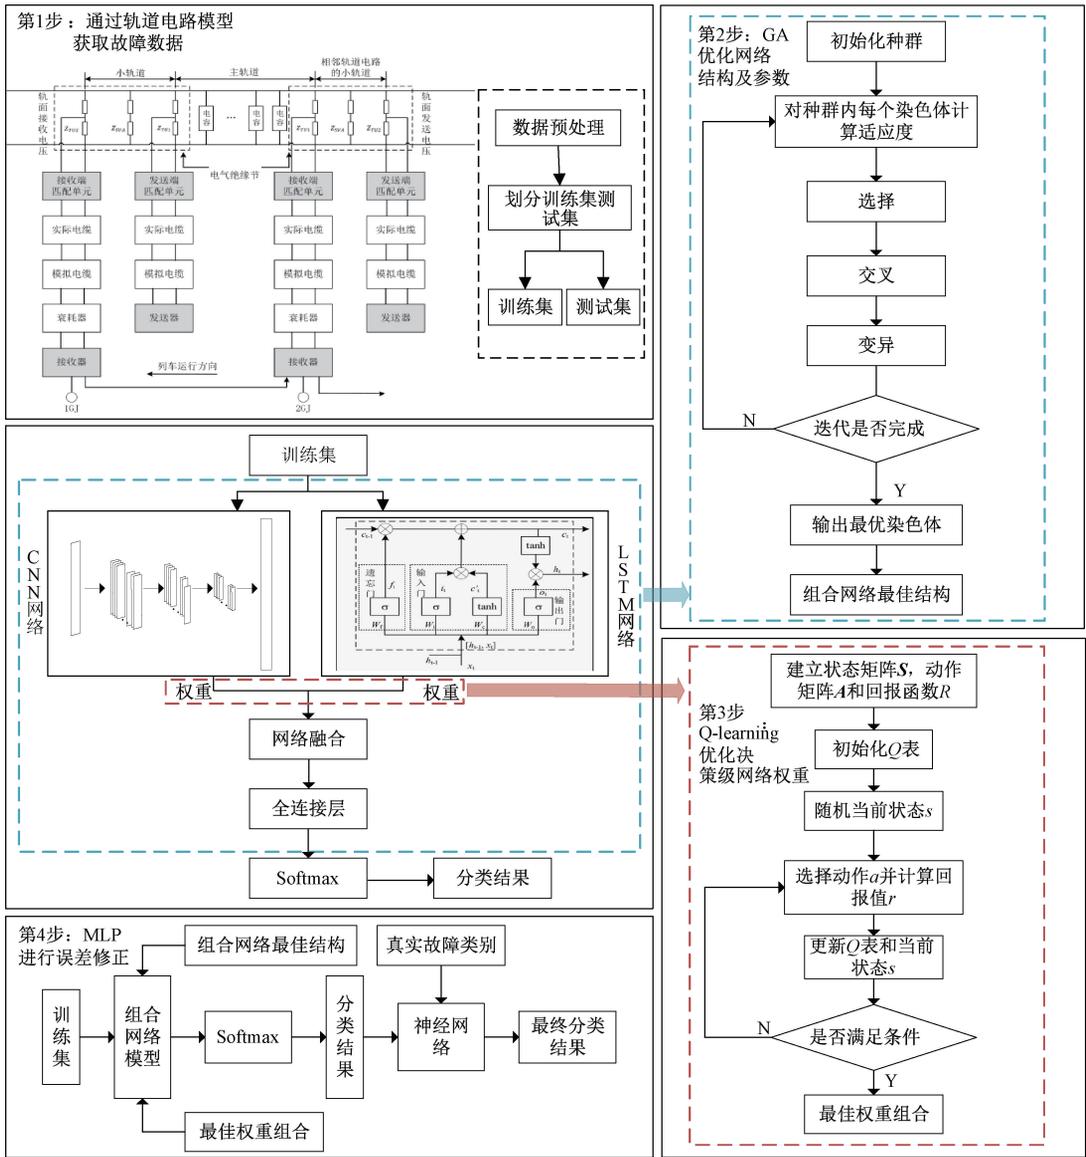


图 1 Intelligent optimization deep network model framework

第 2 步利用遗传算法 (genetic algorithm, GA) 优化卷积神经网络 (convolutional neural network, CNN) 的层数与其对应通道数、长短期记忆网络 (long short-term memory network, LSTM) 隐藏层数和每层的神经元数, 以及全连接层的层数和神经元数。通过此操作可以确定组合深度网络模型各层的详细结构参数值。

第 3 步在获取到最优深度网络模型结构之后, 利用强化学习中的 Q-learning 对组合深度网络的 CNN 和 LSTM 的权重进行搜索, 获得最优组合深度网络权重值。

最后一步, 在上述步骤完成, 得到最优模型结构和最优权重后, 使用组合深度网络模型对训练集进行训练, 将输出结果与真实结果对比得到误差, 将其输入简单的浅

层神经网络中进行拟合并对其修正得到最终的故障诊断结果。

## 2 轨道电路故障诊断网络设计

### 2.1 ZPW-2000A 型轨道电路

ZPW-2000A 轨道电路由主轨道和小轨道两部分组成, 从发送端到接收端, 该型轨道电路由发送器、传输电缆、匹配变压器、钢轨、调谐单元、空心线圈、补偿电容、接收器等构成, 具体结构如图 2 所示。其中, 电气绝缘节由两种调谐单元 TU1 和 TU2, 一个空心线圈 SVA 以及一段钢轨组成, 位于主轨道上的电容即是主轨道的补偿电容,

$Z_{TU1}$ 、 $Z_{TU2}$ 、 $Z_{SVA}$  分别为调谐单元 TU1、TU2 和空心线圈 SVA 的等效阻抗。

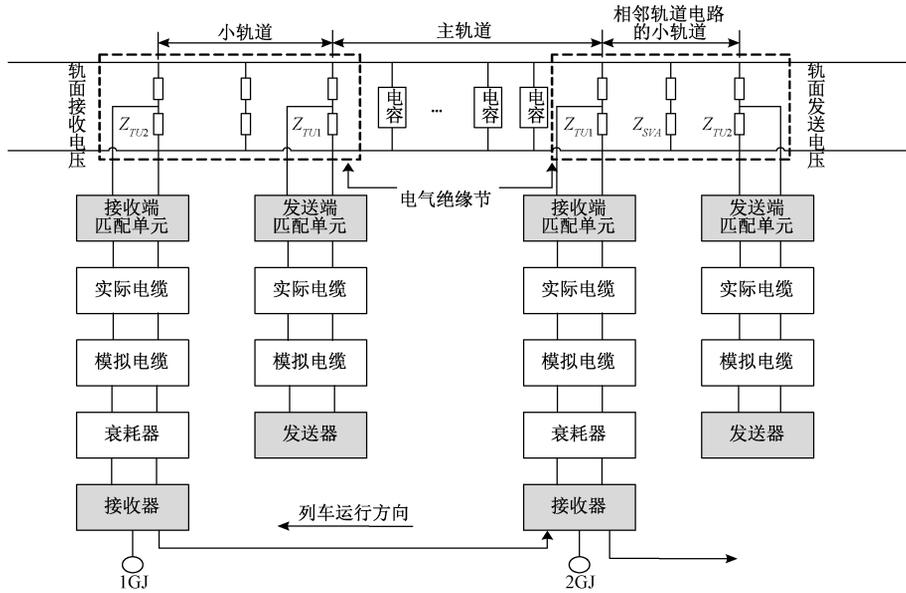


图 2 轨道电路结构

Fig. 2 Track circuit structure

轨道电路的故障发生可通过电路中各电压的变化情况大致判断故障发生范围，部分故障还需要维修人员现场根据自身经验进行相应判断。本文对轨道电路各个设备的故障发生的原因以及故障发生导致的结果等因素综合分析，最终归纳出 19 种轨道电路典型故障，从发送端出发到接收端，对故障的模式及其造成的影响总结如表 1 所示。

表 1 轨道电路典型故障分类表

Table 1 Typical fault classification table of track circuit

故障模式及编号	造成影响
发送电压过高 F1	发送功出电压过高
发送电压过低 F2	发送功出电压过低
发送端模拟网络输出过大 F3	模拟电缆输出电压过高
发送端模拟网络输出过小 F4	模拟电缆输出电压过低
发送端 SPT 电缆故障 F5	送端变压器无(低)电压
发送端匹配变压器故障 F6	送端轨面电压过高(低)
发送端 TU1 故障 F7	送端轨面电压下降
发送端 SVA 故障 F8	送(受)端轨面电压下降
发送端 TU2 故障 F9	送端轨面电压下降
道床电阻过高 F10	受端轨面电压过高
道床电阻过低 F11	受端轨面电压过低
补偿电容故障 F12	受端轨面电压降低
接收端 TU1 故障 F13	受端轨面电压下降
接收端 SVA 故障 F14	送(受)端轨面电压下降
接收端 TU2 故障 F15	受端轨面电压下降
接收端匹配变压器故障 F16	受端轨面电压过高(低)
接收端 SPT 电缆故障 F17	受端变压器无(低)电压
接收端模拟网络输出过大 F18	模拟电缆输出电压过高
接收端模拟网络输出过小 F19	模拟电缆输出电压过低

针对表 1 归纳的故障模式，在分析信号集中监测系统

的监测参量后，本文把 6 个电压监测量作为轨道电路故障数据的特征集，图 2 中灰色单位分别为发送/接收电压，发送/接收匹配电压，轨面电路的虚线框为发送/接收轨面电压。其中，轨道电路正常状态下的样本数据可以在轨道电路正常运行时获取，其他的故障样本则需要通过建立轨道电路仿真模型，通过改变故障所在区域的阻抗值大小来获取对应的故障样本数据。由于轨道电路故障数据集具有不同大小的变化范围，为了进一步提升网络对数据的处理、加快收敛，对数据集统一进行归一化预处理，使数据分布于  $[0, 1]$  区间内，计算公式为：

$$y = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

式中： $y$  为归一化后的数据； $x$  为原始数据； $\min(x)$  和  $\max(x)$  分别为原始数据的最小值和最大值。经归一化后的数据在进一步分为训练集和测试集。

## 2.2 智能优化深度网络设计

### 1) CNN 和 LSTM 组合模型

深度学习具有特征提取能力强、易于处理非线性问题等特点<sup>[17]</sup>，神经网络拥有并行处理、分布式储存和自学习的能力<sup>[18]</sup>，其中的 CNN 具有强大特征提取能力。CNN 是一种前馈神经网络，是由多个滤波阶段和一个分类阶段组成的多阶段网络<sup>[19]</sup>。滤波阶段从输入数据中提取特征，包含卷积运算和池化操作，分类阶段由多个全连接层组成，通过采用层层堆叠的卷积层以及池化层，对输入数据进行充分的特征提取<sup>[20]</sup>。而轨道电路故障的出现往往伴随着信号集中监测系统中监测值的范围性的

变化,因此,将 CNN 优异的特征提取能力运用于轨道电路监测数据上能拥有比传统网络更好的性能。本文对 CNN 的使用主要用于对数据集的特征提取之上,基本结构如图 3 所示。

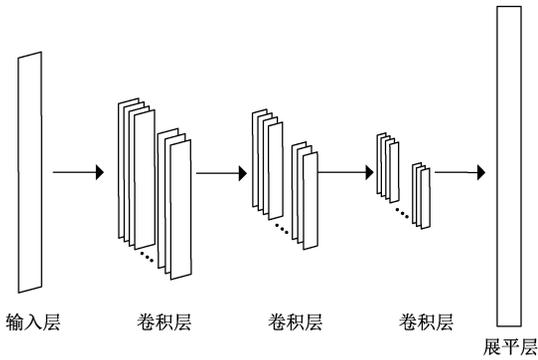


图 3 一维 CNN 结构

Fig. 3 One-dimensional CNN structure

第 1 层为输入层,代表 CNN 的输入参数,即轨道电路的故障特征参数。

第 2 层为卷积层,CNN 通过卷积层不断提取深化特征。使用不同的卷积核对输入数据进行多方位的特征提取,本文使用一维卷积神经网络,具体操作如图 4 所示。

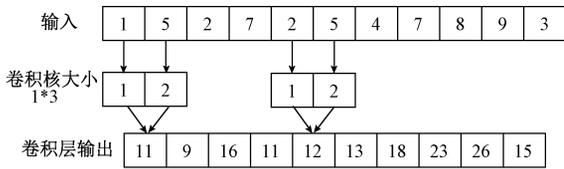


图 4 一维卷积具体操作图

Fig. 4 One-dimensional convolution operation diagram

第 3 层为展平层,传统 CNN 使用此层的目的是将卷积神经网络的输出结构转为全连接层可接受的结构用于分类预测,本文使用展平层的目的同样是为了转化 CNN 输出格式,以便接下来与长短期记忆网络的输出进行融合。

LSTM 是一种改进的时间循环神经网络 (recurrent neural network, RNN),通过加入门控单元有效的缓解了 RNN 中出现的梯度消失和爆炸的问题,可以学习输入数据的长短期依赖信息,在轨道故障诊断领域也出现相关应用<sup>[21]</sup>。LSTM 单元中加入 3 个门,分别为输入门、遗忘门、输出门,输入门控制输入信息的保留程度,遗忘门控制网络是否遗忘历史信息,输出门控制网络输出信息内容。LSTM 结构如图 5 所示。

从图 5 中可以看出,遗忘门由输入  $x_t$  与记忆单元上一时刻状态  $S_{t-1}$ 、LSTM 单元上一时刻中间输出  $h_{t-1}$  共同决定记忆单元的遗忘程度。输入门收到  $x_t$  后分别经过

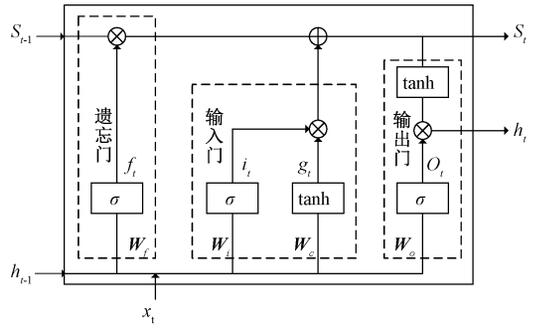


图 5 LSTM 基本单元结构

Fig. 5 LSTM basic unit structure

sigmoid 和 tanh 函数变化后共同决定单元保留信息。单元的中间输出  $h_t$  由更新后的  $S_t$  与  $O_t$  共同确定,各个门中的计算公式如式(2)~(7)所示。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$g_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$S_t = g_t \odot i_t + S_{t-1} \odot f_t \quad (6)$$

$$h_t = \tanh(S_t) \odot o_t \quad (7)$$

其中,  $f_t, i_t, g_t, o_t, S_t$  和  $h_t$  分别表示  $t$  时刻遗忘门、输入门、输入节点、输出门、中间输出和记忆单元的输出;  $W_f, W_i, W_c, W_o$  分别为遗忘门、输入门、输出门以及中间输出相应的权重矩阵;  $b_f, b_i, b_c, b_o$  分别为对应门及中间输出的偏置项;  $\sigma$  表示 sigmoid 函数;  $\odot$  表示向量中元素按位相乘。与模型中 CNN 的作用类似, LSTM 在模型中同样起到深化提取数据特征的作用,使用 CNN 和 LSTM 可分别提取数据集空间及时间的特征信息。

因此,针对单一模型对数据分析提取能力不足且传统机器学习学习能力较差等缺点,本文选用 CNN 和 LSTM 两种深度学习网络的组合模型机特征提取,通过 CNN 分析数据内部的特征信息, LSTM 分析获取数据时间前后的特征信息,对故障数据集进行综合的特征分析提取。相较于普通的并行网络的做法将两个网络提取的特征连接在一起不同,本文将 CNN 提取的特征和 LSTM 网络提取的特征分配权重进行融合,再将融合后的权重输入全连接层最后经过 softmax 得到分类结果。

### 2) GA 优化组合网络结构及参数

GA 是模拟生物进化论中的自然选择和遗传机理的生物进化过程的计算模型,是一种模拟生物进化过程搜索最优解的智能计算方法。目前对 GA 的应用主要为优化网络参数,如文献<sup>[22]</sup>使用 GA 优化 BP 神经网络,文献<sup>[23]</sup>用 GA 对变分模态分解参数进行迭代寻优。

由于神经网络结构的不同会影响网络对信息处理的能力,进而影响网络输出结果。若神经网络的结构选择

出错,可能会造成网络学习能力有限或者过拟合等缺点。目前主流做法是通过其他研究者的经验公式或直接使用其他研究者的网络结构参数来确定自己模型的网络结构,此类做法具有随机性和盲目性,缺少合理性。传统的优化算法可能无法找到全局最优解或者陷入局部最优解。GA 通过使用随机搜索和自适应性的操作,有助于跳出局部最优解,并寻找更好的解决方案。因此,文本引入 GA 算法来对故障诊断基础模型 CNN 和 LSTM 以及融合特征后的全连接层结构进行统一优化,实现步骤如下。

步骤(1)初始化各种参数,初始化种群染色体  $N_{i,j}(n_1, n_2, n_3, n_4, \dots, n_{n_1+n_2+n_3}), i = 1, 2, \dots, NP, j = 1, 2, \dots, \text{gen}$  染色体前 3 位  $n_1, n_2, n_3$  分别代表 CNN、LSTM 和全连接层的层数,每条染色体包含隐藏层和节点的数量,  $(n_4, \dots, n_{n_1+n_2+n_3})$  代表 CNN、LSTM 和全连接层的卷积核、神经元个数,  $i$  代表种群对应的染色体,  $NP$  为种群规模即种群中染色体最大数目,  $j$  代表种群遗传代数,  $\text{gen}$  为最大遗传次数。

步骤(2)计算每条染色体的适应度值,将  $N_{i,j}$  分别带入网络建立对应网络结构的故障诊断网络,使用训练集训练此网络得到分类准确度  $\text{acc}_{i,j}$ ,取出染色体中准确度最高的染色体,保存至  $\text{best\_acc}$  中。

步骤(3)使用轮盘赌的方法从  $N_i$  选择相同数量的染色体并将其保存至  $N_{i,j+1}$  中。

步骤(4)遍历种群  $N_{i,j+1}$  中的染色体,对染色体中每个值进行一次判定,生成随机数  $\text{rand}$ ,若  $\text{rand} < \text{cross\_rate}$ ,  $\text{cross\_rate}$  为初始化的交叉概率,则对此时的值随机选择种群中的一条染色体,取其对应位置的值进行交换错做,以此方法获得两条全新的染色体,将  $N_{i,j+1}$  更新为交叉后的种群。

步骤(5)此步骤同样会进行一次判定,生成随机数  $\text{rand}$ ,若  $\text{rand} < \text{mutat\_rate}$ ,则将此时的值进行一次变异,随机变为可行值中的一个,获得一条新的染色体和全新的种群  $N_{i,j+1}$ 。至此,遗传算法完成一次迭代操作,再判断此时迭代次数是否满足要求,如果不满足则返回步骤(2)进行下一轮遗传。

使用 GA 来确定网络结构,与试验阶段反复测试确定结构或参考其他研究者结构的方式相比此方法显得更加智能和合理。

### 3) Q-Learning 优化特征级输出权重

特征级权重是用于衡量不同特征对最终预测结果的贡献程度的参数。通过优化特征权重,可以提高模型的性能和预测准确度。

Q-learning 是一种基于试错的强化学习算法,适用于在未知环境中进行学习和决策的问题。它通过不断尝试并更新行动-状态对的价值,从而找到最优策略。与一些需要先验知识或模型的算法(如遗传算法)不同, Q-

learning 不需要关于环境和动作的先验知识。在特征权重优化中,可以将每个特征的权重视为一个行动,通过 Q-Learning 来学习最优的特征权重组合。并且单独优化特征权重可以更好地控制和调整特征权重的变化,使其更符合实际需求,提供更好的可解释性,便于调试和分析模型。

Q-Learning 根据一个关于状态  $S$  和动作  $A$  的  $Q$  表进行查表决策和反复更新  $Q$  表的算法。为了融合 CNN 网络输出信息和 LSTM 网络输出信息,在权重分配阶段,组合网络权重的分配有基于实验结果对比的权重分配<sup>[24]</sup>。本文则引入强化学习中 Q-Learning 的思想,使用 Q-Learning 优化组合网络决策级权重,找出最优的权重组合,实现步骤如下。

步骤(1)初始化基本参数值,初始化  $Q$  表,将其值全部置为 0,状态表  $S = (\omega_1, \omega_2, \dots, \omega_m)$ ,动作表  $A = (\Delta\omega_1, \Delta\omega_2, \dots, \Delta\omega_m)$ ,建立回报函数  $R$  如式(8)所示。

$$R = \begin{cases} 10 + \text{acc}(s') - \text{acc}(s) & (\text{acc}(s') > \text{acc}(s)) \\ -10 + \text{acc}(s') - \text{acc}(s) & (\text{acc}(s') < \text{acc}(s)) \end{cases} \quad (8)$$

其中,  $\omega$  为对应的权重值,  $m$  为组合数量,  $\Delta\omega$  为对应权重的变化情况,  $\text{acc}(s)$  为当前状态  $s$  下网络的分类准确率的值,  $\text{acc}(s')$  为下一状态  $s'$  下的网络分类准确率值。

步骤(2)从状态表  $S$  中随机选择初始状态  $s$ ,以  $\varepsilon - \text{greed}$  准则选定动作  $a$ ,  $\varepsilon - \text{greed}$  准则即是,生成随机数  $\text{rand}$ ,若  $\text{rand} < \varepsilon$ ,则 Q-Learning 会选取当前状态下  $Q$  表中的最大值的动作为此状态的动作。若  $\text{rand} > \varepsilon$ ,则会从动作表中随机选取动作进行。

步骤(3)通过回报函数  $R$  计算此状态  $s$  下取动作  $a$  的回报值  $r$ ,并更新  $Q$  表,  $Q$  表更新公式如式(9)、(10)所示。

$$Q(s, a) = Q(s, a) + \alpha(r - Q(s, a)) \quad (9)$$

如果  $s_1$  不是终止状态,更新状态  $s$  下的  $Q$  表,公式如式(10)所示。

$$Q(s, a) = Q(s, a) + \alpha(r + \gamma * \max_{a'}(Q(s', a')) - Q(s, a)) \quad (10)$$

式中:  $Q(s, a)$  为状态  $s$  下动作  $a$  的  $Q$  表值,  $\max_{a'}(Q(s', a'))$  为状态  $s'$  下  $Q$  表中最大值。

步骤(4)判断 Q-Learning 算法探索次数是否达到最大值,如果没有则返回步骤(2)。

### 4) MLP 误差修正

多层感知器(multi-layer perceptron, MLP)是一种前馈神经网络模型。每个神经元都与下一层的所有神经元连接,并且具有权重和偏置。MLP 误差修正通过反向传播算法来实现。在反向传播算法中,首先通过前向传播计算输出,然后计算输出与实际值之间的误差,再根据误差通过链式法则反向传播更新每层神经元的权重,以减

小误差,不断迭代更新权重,使误差收敛到较小的范围。

不同故障诊断模型之间有着各自的特点,任何模型都无法实现对故障的完全正确的分类,分类的结果与真实结果对比都存在有误差,这是模型本身存在的限制。但模型对同一数据输出的误差都有其分布规律,本文通过将模型分类结果输入 MLP 网络中,与真实结果对比,修正组合模型分类结果获得最终的分类结果。因为组合模型输出结果与真实结果相比误差并不会很大,故此使用浅层神经网络 MLP 即可进行修正,提高故障诊断准确率。

### 3 仿真实验及分析

本实验采用 Simulink 模型对轨道电路进行仿真,选取以下 6 个监测量组成原始特征集:发送电压 M1、发送电缆输出电压 M2、发送端轨面电压 M3、接收端轨面电压 M4、接收电缆输入电压 M5、轨入电压 M6。现场测试数据与计算结果对比如表 2 所示。取测量值与任一时刻仿真值计算相对误差和绝对误差,公式如下:

$$\text{绝对误差} = |\text{测量值} - \text{仿真值}| \quad (11)$$

$$\text{相对误差} = |\text{测量值} - \text{仿真值}| / \text{仿真值} \quad (12)$$

由表 2 可见,仿真结果与现场测试数据的最大相对误差在发送端轨面电压处,数值为 4.80%,表明本文所建立的轨道电路仿真模型具有较高的精确度。

表 2 现场测试数据与仿真结果对比

Table 2 Comparison of field test data and simulation results

数据特征	仿真值/V	测量值/V	绝对误差	相对误差/%
M <sub>1</sub>	104	104	0	0
M <sub>2</sub>	34.28	34.65	0.37	1.07
M <sub>3</sub>	2.97	3.12	0.15	4.80
M <sub>4</sub>	2.61	2.61	0	0
M <sub>5</sub>	20.19	20.51	0.32	1.58
M <sub>6</sub>	2.3	2.24	0.06	2.60

本实验以 2.1 节中的 6 个电压监测量作为故障诊断模型的输入。故障样本数据总共为 1 383 组,分别对每个类型的故障取其 20% 作为测试集,80% 为训练集供网络训练和性能测试,样本数据集分布如表 3 所示,各模型的训练迭代次数为 35,批处理大小为 36。

#### 3.1 评价指标公式

本文拟采用以下 5 个指标评价模型性能。

1) 分类准确率  $acc$ ,  $acc$  越大代表准确率越高,模型越好。

$$acc = \frac{\text{分类正确样本数}}{\text{总样本数}} \quad (13)$$

表 3 故障样本分布

Table 3 Fault sample distribution

故障编号	训练样本	测试样本	故障编号	训练样本	测试样本
F1	74	19	F11	49	13
F2	70	18	F12	56	15
F3	62	16	F13	62	16
F4	58	15	F14	66	15
F5	63	16	F15	49	13
F6	43	11	F16	41	11
F7	37	10	F17	40	11
F8	50	13	F18	45	12
F9	53	14	F19	59	15
F10	43	11	F20	60	15

2) 交叉熵损失  $L$ ,  $L$  越小代表分类误差越小,模型越好。

$$L = -\frac{1}{n} \sum_{i=1}^n \sum_{k=1}^c (y_k^i \cdot \log(\hat{p}_k^i)) \quad (14)$$

其中,  $n$  为样本总数,  $c$  为类别总数,  $y_k^i$  为第  $i$  个样本第  $k$  类标签值,  $\hat{p}_k^i$  表示模型将第  $i$  个样本分类为第  $k$  类标签值的概率。本文后面对测试集评价模型的准确率  $acc$  值和损失  $L$  的值取 10 次实验的平均值。

3) 准确率

$$Precision = TP / (TP + FP) \quad (15)$$

4) 召回率

$$Recall = TP / (TP + FN) \quad (16)$$

5) 精确率和召回率的加权平均值  $F_1$

$$F_1 = (2Recall \times Precision) / (Recall + Precision) \quad (17)$$

式中:真正类  $TP$  为正类被预测为正类的样本数目,假负类  $FN$  为正类被预测为负类的样本数目,假正类  $FP$  为负类被预测为正类的样本数目,真负类  $TN$  为负类被预测为负类的样本数目。

#### 3.2 GA 优化网络结构及参数

CNN 的卷积层数与每层对应卷积层的通道数的结构参数,LSTM 的层数和每层对应神经元个数的结构参数,以及最终特征输入全连接层,全连接层的层数与每层的神经元个数共同构成深度网络模型的结构参数。将这些结构参数转为 GA 中对应的染色体进行网络评价后,通过对比每种结构下的  $acc$  来对此种结构进行评价。本研究的初始模型结构如图 6 所示,在优化中将 CNN 的层数的搜索范围定义在  $[1, 4]$ ,LSTM 网络层数的搜索范围定义在  $[1, 6]$ ,全连接层的搜索范围在  $[1, 4]$ ,GA 中,网络隐含层及节点数量范围分别设为  $[1, 4]$  和  $[1, 150]$ ,交叉概率 0.4,变异概率 0.05,最大迭代次数 100,得到的最优网络结构是 CNN 有 2 个卷积层,第 1 层通道数为 44,第 2 层通道数为 31,LSTM 网络有 6 层,从第 1 层~第 6

层对应的神经元(神经元个数)分别问 31、9、20、14、24、12,全连接层为 2 层,神经元数对应为 75 和 89。目标函数为网络学习的  $acc$ ,目标函数值越大,其对应的适应值就越大。本文采用目标函数值作为适应值,以网络结构为优化目标,GA 优化的目标函数具体数学表达式同式(13)。图 6 中展示了 GA 优化时模型精度的提高曲线。获得此结构后,通过实验建立结构对应故障诊断网络模型再与没有优化的模型进行实验对比,结果如表 4 所示。

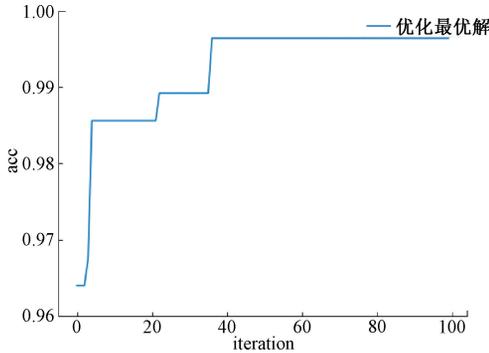


图 6 GA 优化网络结构迭代过程

Fig. 6 Process of GA optimization of model structure

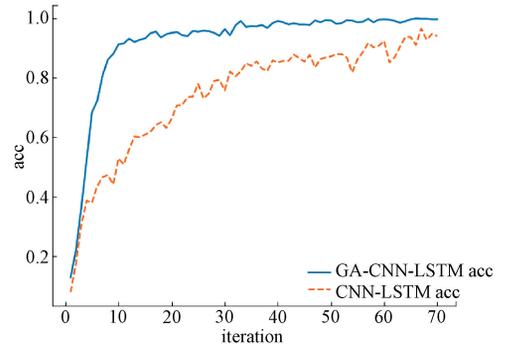
表 4 初始模型参数

Table 4 Initial model parameters

模型名称	输入尺寸	输出尺寸
Input	(None, 1, 6)	(None, 1, 6)
Reshape	(None, 1, 6)	(None, 1, 6, 1)
Conv2D_1	(None, 1, 6, 1)	(None, 1, 5, 32)
Conv2D_2	(None, 1, 5, 32)	(None, 1, 4, 64)
Conv2D_3	(None, 1, 4, 64)	(None, 1, 3, 64)
Flatten	(None, 1, 3, 64)	(None, 192)
Dense_1	(None, 192)	(None, 128)
LSTM_1	(None, 1, 6)	(None, 1, 64)
LSTM_2	(None, 1, 64)	(None, 1, 128)
LSTM_3	(None, 1, 128)	(None, 1, 64)
LSTM_4	(None, 1, 64)	(None, 1, 32)
Dense_2	(None, 32)	(None, 128)
Concatenate	(None, 128)	(None, 256)
Dense_3	(None, 256)	(None, 64)
Dense_4	(None, 64)	(None, 32)
Dense_5	(None, 32)	(None, 21)

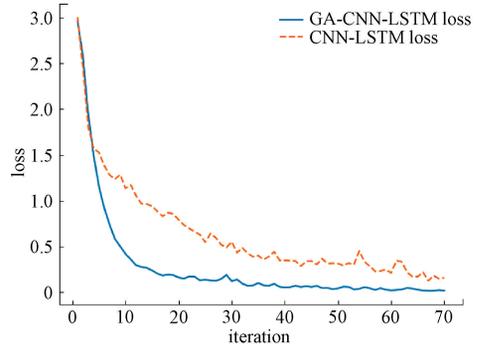
如图 7 (a) 所示,在网络经过 70 次训练下,使用 GA 优化后的网络模型在收敛速度和准确率上都得到了较为明显的提升,从图 7 (b) 中也可以明显看出经过优化后的网络性能得到的很大的提升。利用测试集对两种模型进行对比结果如表 5 所示。

从图 7 和表 5 可以看出,GA 优化后的网络模型在训练集上和测试集上相较于未优化的网络模型有着较为明



(a) GA 优化网络前后 acc 变化曲线

(a) GA optimization network before and after the change curve



(b) GA 优化网络前后损失 L 变化曲线

(b) The loss curve before and after GA optimization network

图 7 GA 优化网络前后对比

Fig. 7 Comparison before and after GA optimization network

表 5 GA 优化前后测试集对比

Table 5 Comparison of test sets before and after GA optimization

模型	acc/%	L
CNN-LSTM	90.29	0.220 24
GA-CNN-LSTM	94.24	0.163 08

显的提升,通过 GA 优化得到的网络在训练集上收敛速度更快,在测试集上也有着比未优化网络更高的准确率和更低的损失值,GA 优化后的网络在准确率  $acc$  上从原本的 90.29 提升到了 94.24,提升了 3.95%,损失值  $L$  下降了 0.057 16。实验结果证明 GA 优化网络结构不仅能确定网络结构及参数,为结构与参数的确定提供依据,而且优化后的模型拥有更好的性能。

### 3.3 Q-Learning 优化权重

3.2 节中进行的对比实验在 CNN 和 LSTM 网络的融合阶段采用的是随机定义两个权重进行特征相加,在通过全连接层分析分类。为了全面、合理的分配组合模型在融合时的权重,本节利用强化学习 Q-Learning 对组合网络权重融合进行探索,利用 Q-Learning 智能的获得最佳权重,而不是借助于实验反复尝试然后人为主观的分配。通过 Q-Learning 的反复探索获得的最佳权重,再与

随机分配权重的网络模型进行对比,模型在训练集上的实验对比结果如图 8 所示。

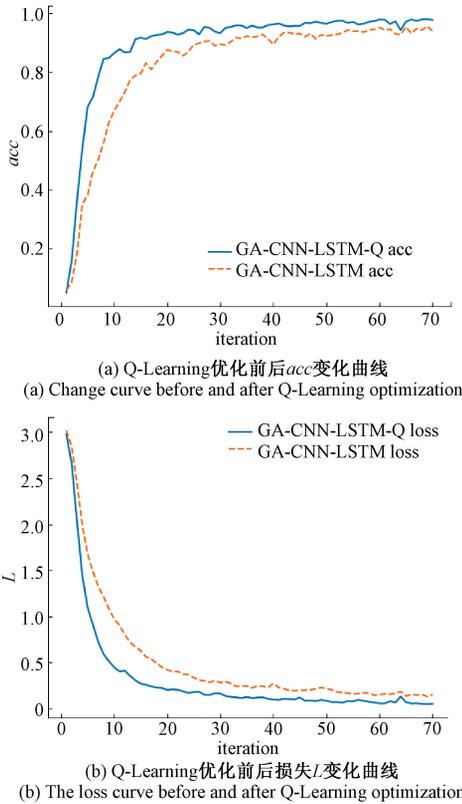


图 8 Q-Learning 优化前后对比

Fig. 8 Comparison of Q-Learning before and after optimization

如图 8 所示, Q-Learning 优化后的模型对比模型是 3.2 节中经过 GA 优化过结构的模型,此模型在训练集上已经有着较好的表现,但通过 Q-Learning 优化后,模型得到了更进一步的提升,无论是准确率  $acc$  的变化曲线还是损失值  $L$  的变化曲线都得到了一定的提升,且模型的收敛速度得到了更进一步的提升。以下再用测试集评价 Q-Learning 优化后的模型,并与优化前的模型对比,结果如表 6 所示。

表 6 Q-Learning 优化前后测试集对比

Table 6 Comparison of test sets before and after Q-Learning optimization

模型	$acc/\%$	$L$
GA-CNN-LSTM	94.24	0.163 08
GA-CNN-LSTM-Q	96.41	0.104 10

从表 6 可以看出, Q-Learning 优化权重后的模型相比于优化前的模型在测试集上准确率  $acc$  从 94.24 提升到 96.41, 损失值  $L$  降低了 0.058 98。总结图 8 和表 6 可以得出结论, 组合网络权重会对网络性能产生影响, 因此经过 Q-Learning 优化权重后的网络在性能上得到提升的表

现符合预期, 且实验也验证了 Q-Learning 在搜索组合网络权重上的可行性, 为组合网络权重的分配提供其合理性。

### 3.4 误差拟合修正

实验使用神经网络以 GA 和 Q-Learning 优化后网络模型的分类结果和真实结果对比作为神经网络的输入, 对误差拟合修正输出最终的分类结果, 使用浅层神经网络多层感知器 MLP 作为模型, 利用 BP 算法训练网络模型, 实验结果与 Q-Learning 后的模型结果进行对比, 训练集上的表现如图 9 所示, 测试集上的表现如表 7 所示。

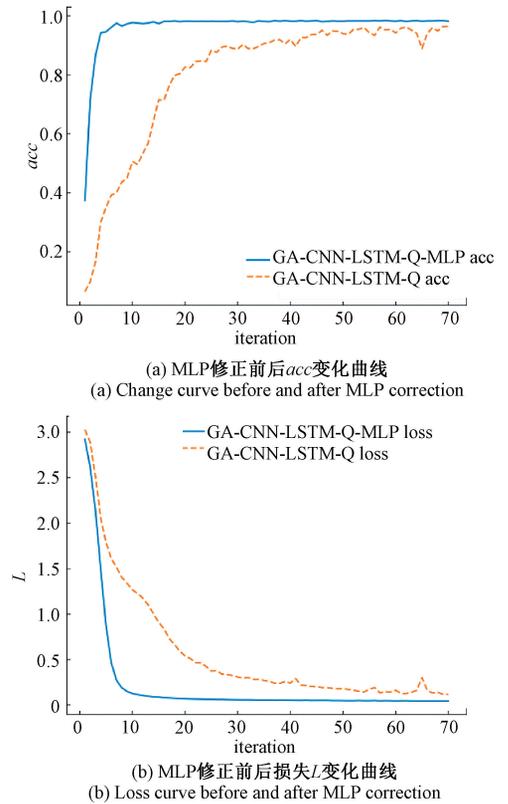


图 9 MLP 修正前后对比

Fig. 9 Comparison before and after MLP correction

表 7 MLP 修正前后测试集对比

Table 7 Comparison of test sets before and after MLP correction

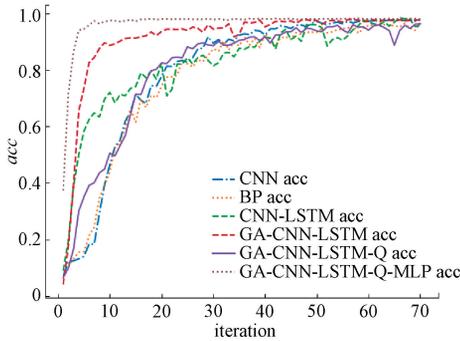
模型	$acc/\%$	$L$
GA-CNN-LSTM-Q	96.41	0.104 10
GA-CNN-LSTM-Q-MLP	99.28	0.067 39

分析图 9 和表 7, 因为 MLP 是对已经经过 GA 优化网络结构, Q-Learning 优化组合权重后的模型进行的结果修正, 此模型无论是在训练集还是测试集都有着非常好的表现, 故 MLP 在这一步优化时, 在训练集中的表现没有太明显, 但依然能看出, 经过 MLP 优化后的模型在

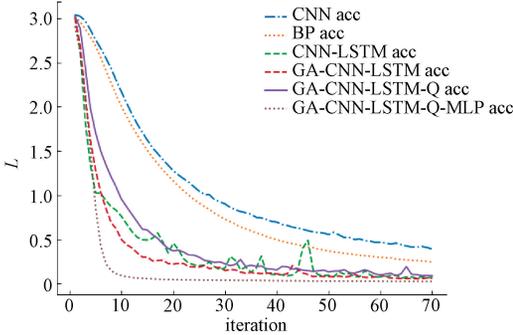
准确率  $acc$  的变化曲线和损失  $L$  的变化曲线都有着比之前一定的提升,在测试集上的结果更是证明了这一点,MLP 修正后的模型在测试集准确率  $acc$  提升到 99.28%,损失值  $L$  也下降到 0.067 39,证明优化的成功和此方法的优异表现。

### 3.5 优化模型试验对比

轨道电路故障诊断常用的方法有支持向量机 SVM、BP 神经网络、CNN 等,将经过 GA 优化结构、Q-Learning 优化权重和 MLP 修正误差的深度网络模型与以上几种常用模型对比,并加入中间每一步优化的模型参与对比,利用训练集上的准确率  $acc$  和损失  $L$  的变化曲线情况和测试集上的准确率  $acc$  和损失  $L$  的结果对比几种深度网络模型的性能,对于支持向量机 SVM,使用测试集上的准确率  $acc$  进行对比,最终实验结果如图 10 和表 8 所示。



(a) 各模型对比  $acc$  变化曲线  
(a) Comparative change curve of each model



(b) 各模型对比损失  $L$  变化曲线  
(b) Contrast loss curve of each model

图 10 训练集各模型对比

Fig. 10 Comparison of models in training set

表 8 测试集各模型结果对比

Table 8 Comparison of model results in test set

模型	$acc/\%$	$L$
SVM	88.85	0.245 41
BP	84.53	0.750 85
CNN	88.86	0.418 09
CNN-LSTM	90.29	0.220 24
GA-CNN-LSTM	94.24	0.163 08
GA-CNN-LSTM-Q	96.41	0.104 10
GA-CNN-LSTM-Q-MLP	99.28	0.067 39

从图 10 和表 8 可以看出,CNN 组合 LSTM 网络性能要优于单一模型和传统机器学习模型,且利用 GA 优化 CNN 和 LSTM 及全连接层网络结构,Q-Learning 优化组合权重,最后使用 MLP 进行误差修正,3 步优化调整相较于之前的模型在故障诊断上各方面性能都得到提升。本文提出的 GA-CNN-LSTM-Q-MLP 深度网络模型对故障的识别率可达 99.28%,证明了模型的优异型,故障识别率高。

表 9 给出了不同集成模型的性能指标比较。从表 9 的数据可看出,经过本文提出的智能优化能提高整体模型的故障诊断性能。

表 9 不同集成模型的性能指标比较

Table 9 Comparison of performance indexes of different integration models

方法	准确率	召回率	$F_1$
LSTM	0.926 4	0.918 7	0.905 2
CNN-LSTM	0.932 0	0.911 9	0.904 1
GA-CNN-LSTM	0.939 4	0.928 1	0.920 7
GA-CNN-LSTM-Q	0.901 4	0.925 6	0.908 0
GA-CNN-LSTM-Q-MLP	0.968 9	0.965 8	0.964 4

## 4 结 论

本文以无绝缘轨道电路故障为工程背景,提出 CNN 和 LSTM 网络智能组合深度网络模型,从空间和时间两个维度综合进行特征提取,可提升后续诊断精度。从网络结构和组合权重对模型性能会造成影响且模型结构和组合权重的确定具有随机性和盲目性,利用 GA 优化深度网络层数、神经元等结构参数,在决策级参数优化中采用能够适应不同工况的强化学习 Q-Learning 进行组合权重优化。最后通过多层感知器对组合模型结果误差进行拟合修正。并且对每一步优化进行仿真对比实验,仿真结果表明本文所提出的智能优化深度网络模型能够精准诊断轨道电路故障,具有相当高的故障识别率。在工程验证方面,可以将所提模型应用于实际轨道电路故障诊断系统中,进一步验证其在实际工程中的适用性和可靠性。

## 参考文献

[ 1 ] 康伟. ZPW-2000 轨道电路故障分析及研究 [ D ]. 北京:中国铁道科学研究院,2019.  
KANG W. Fault analysis and research of ZPW-2000 track circuit [ D ]. Beijing: China Academy of Railway Sciences,2019.

[ 2 ] 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 railway jointless track circuit based on combinatorial decision tree [J]. Railway Journal, 2018, 40 (7): 74-79.
- [3] 张友鹏,常高武,赵斌. 基于SA算法的无绝缘轨道电路故障综合检测方法[J]. 铁道学报, 2017, 39(4): 68-72.  
ZHANG Y P, CHANG G W, ZHAO B. A comprehensive fault detection method for jointless track circuit based on SA algorithm [J]. Railway Journal, 2017, 39 (4): 68-72.
- [4] 赵林海,冉义奎,穆建成. 基于遗传算法的无绝缘轨道电路故障综合诊断方法[J]. 中国铁道科学, 2010, 31(3): 107-114.  
ZHAO L H, RAN Y K, MU J CH. Comprehensive fault diagnosis method for jointless track circuit based on genetic algorithm [J]. China Railway Science, 2010, 31(3): 107-114.
- [5] 王彤. 基于最小二乘支持向量机的轨道电路故障诊断方法[J]. 铁道标准设计, 2014, 58(2): 89-93.  
WANG T. Track circuit fault diagnosis method based on least squares support vector machine [J]. Railway Standard Design, 2014, 58(2): 89-93.
- [6] 黄赞武,魏学业,刘泽. 基于模糊神经网络的轨道电路故障诊断方法研究[J]. 铁道学报, 2012, 34(11): 54-59.  
HUANG Z W, WEI X X, LIU Z. Fault diagnosis of railway track circuit using fuzzy neural network [J]. Journal of the China Railway Society, 2012, 34(11): 54-59.
- [7] 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. Fault diagnosis of jointless track circuit based on deep learning [J]. Journal of the China Railway Society, 2020, 42(6): 79-85.
- [8] 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 F X, YANG SH W, CUI Y, et al. Fault diagnosis of tuning zone of jointless track circuit based on improved convolutional neural network [J]. Railway Computer Application, 2020, 29(6): 58-63, 74.
- [9] 米根锁,杨润霞,梁利. 基于组合模型的轨道电路复杂故障诊断方法研究[J]. 铁道学报, 2014, 36(10): 65-69.  
MI G S, YANG R X, LIANG L. Research on diagnosis method of complex fault diagnosis of track circuit based on combined model [J]. Journal of the China Railway Society, 2014, 36(10): 65-69.
- [10] 郑云水,牛行通,康毅军. 蝙蝠算法优化模糊神经网络的25 Hz相敏轨道电路故障诊断研究[J]. 铁道学报, 2018, 40(12): 93-100.  
ZHENG Y SH, NIU X T, KANG Y J. Fault diagnosis research for 25 Hz phase sensitive track circuit based on bat algorithm to optimized fuzzy neural network [J]. Journal of the China Railway Society, 2018, 40(12): 93-100.
- [11] 陈欣. 基于粒子群支持向量机的轨道电路故障诊断[J]. 铁路计算机应用, 2016, 25(8): 56-58, 63.  
CHEN X. Track circuit fault diagnosis based on particle swarm optimization and support vector machine [J]. Railway Computer Application, 2016, 25 (8): 56-58, 63.
- [12] 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 G W, GAO Y L, JIAO X M. Track circuit fault diagnosis based on adaptive mutation SAPSO-LSSVM [J]. Journal of Beijing Jiaotong University, 2021, 45(2): 1-7.
- [13] ZHENG Z, DAI S, XIE 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.
- [14] 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.
- [15] 王力,刘学朋,张亦弛. 基于BCL-ASA-BP神经网络的模拟电路板芯片故障诊断[J]. 电子测量技术, 2022, 45(14): 164-171.  
WANG L, LIU X P, ZHANG Y CH. Fault diagnosis of analog circuit board chip based on BCL-ASA-BP neural network [J]. Electronic Measurement Technology, 2022, 45(14): 164-171.
- [16] 凌立文,张大斌. 组合预测模型构建方法及其应用研究综述[J]. 统计与决策, 2019, 35(1): 18-23.  
LING L W, ZHANG D B. Summary of research on the construction method and application of combined forecasting model [J]. Statistics and Decision-Making, 2019, 35 (1): 18-23.
- [17] 王雨虹,王志中,付华,等. 多策略改进麻雀算法与

- BiLSTM 的变压器故障诊断研究[J]. 仪器仪表学报, 2022, 43(3): 87-97.
- WANG Y H, WANG ZH ZH, FU H, et al. Research on transformer fault diagnosis based on improved multi-strategy sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [18] 单显明, 李长伟, 张忠传. 基于神经网络的复杂电子设备故障诊断系统的设计[J]. 电子测量技术, 2022, 45(11): 52-56.
- SHAN X M, LI CH W, ZHANG ZH ZH. Design of fault diagnosis system for complex electronic equipment based on neural network [J]. Electronic Measurement Technology, 2022, 45(11): 52-56.
- [19] 韩宇, 李剑, 马慧宇, 等. 基于 CNN-LSTM 的桥梁结构损伤诊断方法[J]. 国外电子测量技术, 2021, 40(7): 1-6.
- HAN Y, LI J, MA H Y, et al. Bridge structure damage diagnosis method based on CNN-LSTM [J]. Foreign Electronic Measurement Technology, 2021, 40(7): 1-6.
- [20] 杨春柳. 基于卷积神经网络的多层域自适应滚动轴承故障诊断[J]. 电子测量与仪器学报, 2021, 35(2): 122-129.
- YANG CH L. Multi-domain adaptive rolling bearing fault diagnosis based on convolutional neural networks [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 122-129.
- [21] 康玄焯, 赵林海, 孟景辉, 等. 基于 LSTM 的轨道电路补偿电容故障数量预测[J]. 铁道学报, 2021, 43(1): 94-99.
- KANG X Y, ZHAO L H, MENG J H, et al. LSTM-based on forecasting for number of track circuit compensation capacitor [J]. Journal of the China Railway Society, 2021, 43(1): 94-99.
- [22] 马健, 滕召胜, 邱伟, 等. 基于 IGA-BP 神经网络的智能电能计量设备退化趋势研究[J]. 仪器仪表报, 2021, 42(11): 123-131.
- MA J, TENG ZH SH, QIU W, et al. Research on the degradation trend of smart energy metering equipment based on IGA-BP neural network [J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 123-131.
- [23] 简定辉, 李萍, 黄宇航. 基于 GA-VMD-ResNet-LSTM 网络的短期电力负荷预测[J]. 国外电子测量技术, 2022, 41(10): 15-22.
- JIAN D H, LI P, HUANG Y H. Short-term power load forecasting based on GA-VMD-ResNet-LSTM network [J]. Foreign Electronic Measurement Technology, 2022, 41(10): 15-22.
- [24] 董煜, 董昱. 基于方法组合的轨道电路故障诊断模型[J]. 铁道标准设计, 2019, 63(05): 143-147.
- DONG Y, DONG Y. Fault diagnosis model of track circuit based on method combination [J]. Railway Standard Design, 2019, 63(5): 143-147.

### 作者简介



彭菲桐, 2018 年于贵州师范学院获得学士学位, 现为重庆交通大学硕士研究生, 主要研究方向为深度学习与故障诊断。

E-mail: 595238337@qq.com

Peng Feitong received her B. Sc. degree from Guizhou Education University in 2018.

Now she is a M. Sc candidate at Chongqing Jiaotong University. Her main research interests include deep learning and fault diagnosis.



徐凯(通信作者), 2002 年于重庆大学获得硕士学位, 现为重庆交通大学教授, 主要研究方向为机器学习、计算智能、轨道交通自动化与控制。

E-mail: xkxjwx@hotmail.com

Xu Kai (Corresponding author) received his M. Sc. degree from Chongqing University in 2002. Now he is a professor at Chongqing Jiaotong University. His main research interests include machine learning, computational intelligence, automation and control of urban rail train.