

DOI: 10.13382/j.jemi.B2205245

基于 DBN-MPA-LSSVM 的无绝缘轨道电路故障诊断研究*

林俊亭 王 帅

(兰州交通大学自动化与电气工程学院 兰州 730070)

摘要:针对区间无绝缘轨道电路故障类型复杂、诊断精度低等问题,从故障特征提取和特征分类两方面出发,提出了一种深度置信网络(DBN)和海洋捕食者算法(MPA)优化最小二乘支持向量机(LSSVM)的故障诊断方法。首先,将集中监测数据和状态标签输入到DBN,以半监督的方式进行降维和特征提取,从而挖掘轨道电路不同故障特征信息;然后,采用MPA智能算法对LSSVM的惩罚因子和核函数参数进行寻优并建立最优MPA-LSSVM诊断模型;最后,将DBN提取的特征样本导入诊断模型进行轨道电路的故障分类识别。DBN-MPA-LSSVM诊断模型充分利用了DBN在特征提取过程中的逐层提取优势以及LSSVM在解决小样本情况下高维模式识别的优势。实验验证与对比分析表明,DBN-MPA-LSSVM模型测试集准确率为98.33%,MPA优化算法较PSO、GWO、GA算法模型诊断准确率分别提高了6.11%、3.89%、3.33%,平均准确率为97.98%,为基于数据驱动的轨道电路故障诊断技术提供了一种新的方法。

关键词:无绝缘轨道电路;深度置信网络;海洋捕食者算法;最小二乘支持向量机;故障诊断

中图分类号: 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 jointless track circuit based on DBN-MPA-LSSVM

Lin Junting Wang Shuai

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

Abstract: Aiming at the problems of complex fault types and low diagnosis accuracy of section jointless track circuit, a fault diagnosis method of least squares support vector machine(LSSVM) optimized by deep belief network(DBN) and marine predators algorithm(MPA) is proposed from the two aspects of fault feature extraction and feature classification. Firstly, the centralized monitoring data and status labels are input into DBN, and the dimensionality reduction feature extraction is carried out in a semi supervised way, so as to mine the different fault feature information of track circuit. Then, the intelligent algorithm MPA is used to optimize the penalty factor and kernel function parameters of LSSVM, and the optimal MPA-LSSVM diagnosis model is established. Finally, the feature samples extracted by DBN are introduced into the diagnosis model for fault classification and identification of track circuit. DBN-MPA-LSSVM diagnostic model makes full use of the advantages of layer by layer extraction of DBN in the process of feature extraction and the advantages of LSSVM in solving high-dimensional pattern recognition in the case of small samples. Experimental validation and comparative analysis show that the DBN-MPA-LSSVM model test set accuracy is 98.33%, and the MPA optimization algorithm improves the diagnosis accuracy by 6.11%, 3.89%, and 3.33% compared with PSO, GWO, and GA algorithm models, respectively, with an average accuracy of 97.98%, which provides a new data-driven rail circuit fault diagnosis technology based on method.

Keywords: jointless track circuit; deep belief network; marine predators algorithm; least squares support vector machine; fault diagnosis

0 引 言

轨道电路是中国列车运行控制系统(Chinese train control system, CTCS)地面设备的重要组成部分,其大量

部件分布于室外,故障类型复杂,一旦发生故障会直接影响列车行车效率甚至危及行车安全^[1]。近年来,各铁路局已经逐步安装了信号集中监测系统,对轨道电路运行过程中产生的状态数据实现了监测和采集,但缺乏对所采数据进行智能分析。现场对于轨道电路的故障判别仍

收稿日期: 2022-03-08 Received Date: 2022-03-08

* 基金项目: 国家自然科学基金(52162050)、中国铁道科学研究院科研基金(2021YJ205)项目资助

然采用传统的阈值法,其数据分析工作依赖大量人工参与,导致现场维护效率偏低,智能化程度较低^[2]。因此,通过引入智能诊断方法,从轨道电路运行数据中挖掘有用信息,辅助现场维护人员及时准确地实现故障诊断在铁路工程应用方面具有重要意义^[3]。

目前国内外学者针对轨道电路故障诊断提出了基于物理模型、信号处理以及数据驱动等方法。在物理模型方面,通过建立轨道电路四端网等效模型^[4],从而获取轨面电压曲线及相应轨道参数。但轨道电路所处环境复杂,建立的模型精确与否会直接影响到故障诊断性能,其适应性较低。在信号处理方面,文献[5]利用改进型卷积神经网络对轨道电路读取器曲线进行特征提取,达到了故障诊断的目的。文献[6]利用梅尔频率谱系数和动态时间规整算法建立了轨道电路诊断模型。然而基于信号处理的故障诊断技术只能对信号本身的特点进行分析,很难挖掘到真正有用的特征。近年来大部分学者利用机器学习和深度学习实现了基于数据驱动的故障诊断方法。文献[7]利用蝙蝠算法优化模糊神经网络,实现了 25 Hz 相敏轨道电路故障诊断。文献[8]提出一种具有长短期记忆的循环神经网络,通过对网络进行训练实现故障诊断。深度置信网络(deep belief network, DBN)具有强大的特征提取能力,通过对每一层的受限玻尔兹曼机逐层进行无监督训练,挖掘数据内部特征并降维。文献[9]运用 DBN 提取轨道电路故障数据的分布式特征,结合 BP 神经网络实现了轨道电路的故障分类。最小二乘支持向量机(least squares support vector machine, LSSVM)在解决小样本、非线性及高维模式识别中具有较强优势,其分类精度受惩罚参数和核函数参数影响较大。文献[10]提出一种将模拟退火算法和粒子群最小二乘支持向量机相结合的轨道电路故障诊断方法,得到了较好的识别结果。海洋捕食者算法(marine predators algorithm, MPA)是一种基于海洋适者生存理论而提出的新型元启发式优化算法,与粒子群算法、遗传算法、灰狼算法等相比,MPA 可以以更低的计算成本获得与其他方法相当或优于其他算法的解,收敛速度快,运行更稳定。文献[11]利用变分模态分解提取滚动轴承特征向量,结合 MPA 优化的 LSSVM 诊断模型实现了轴承的智能诊断。

通过以上分析,提出一种基于 DBN 和 MPA-LSSVM 的轨道电路故障诊断方法。首先,根据 ZPW-2000 轨道电路的组成特点,分析轨道电路不同故障模式并通过集中监测系统获取真实数据;然后利用深度置信网络提取出多维度特征向量作为系统输入,提高故障诊断精度;最后利用 MPA-LSSVM 诊断模型进行故障诊断。测试结果显示,该方法能够对轨道电路的多故障类型进行有效识别,能够提升集中监测系统对铁路设备的故障诊断性能。

1 基于 DBN-MPA-LSSVM 的故障诊断方法

1.1 深度置信网络

深度置信网络(DBN)^[12]是一种由多层隐藏受限玻尔兹曼机(restricted Boltzmann machine, RBM)堆叠而成的概率生成模型,其典型结构如图 1 所示。RBM 由可见层 v 和隐藏层 h 构成,每一层的单元之间都有双向连接,但每一层中的单元互相独立。可见层神经元可以表示为 $v = \{v_1, v_2, \dots, v_n\}$,隐藏层神经元可以表示为 $h = \{h_1, h_2, \dots, h_m\}$,其能量函数为:

$$E(v, h) = - \sum_{i=1}^n v_i a_i - \sum_{j=1}^m h_j b_j - \sum_{i=1}^n \sum_{j=1}^m h_i v_i w_{ij} \quad (1)$$

其中, w_{ij} 为可见层单元 i 与隐藏层单元 j 的连接权值; a_i 是可见层单元 i 的偏移量; b_j 是隐藏层单元 j 的偏移量。

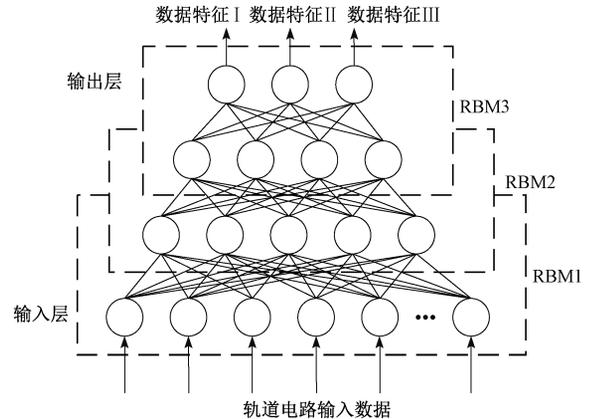


图 1 DBN 结构示意图

Fig. 1 DBN structure diagram

DBN 方法对轨道电路故障特征提取过程分为预训练和微调两个阶段。在预训练阶段,将不同类型的轨道电路故障数据输入到深度置信网络的第 1 层 RBM 进行无监督训练,将训练得到的输出作为下一层的输入,以此逐层传递贪婪学习,直到输出层输出轨道电路故障特征。微调阶段是一个有监督学习的过程,输出结果与标签数据进行对比,利用误差反向传播算法对 DBN 进行逆向训练,完成参数寻优。

1.2 MPA 优化 LSSVM

本文采用最小二乘支持向量机 LSSVM 作为 DBN 顶层分类器模型。LSSVM 采用最小二乘法将 SVM 中的不等式约束转换为等式约束,将其训练过程转化为线性方程组求解,简化了算法的复杂性^[13]。首先建立如下分类问题求解方程:

$$\begin{aligned} \min_{\omega, b, e} F(\omega, b, e) &= \frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{i=1}^m e_i^2 \\ \text{s. t. } & y_i [\omega^T \varphi(x_i) + b] = 1 - e_i \\ & \gamma > 0, i = 1, 2, \dots, m \end{aligned} \quad (2)$$

式中: e 为偏差向量; γ 表示权重, 也叫惩罚因子; ω 为 LSSVM 的权系数向量; y_i 为类别标签; b 为阈值; φ 为核函数, 使得样本在更高维空间内线性可分。

引入拉格朗日函数求解该函数的最大值条件, 解得 LSSVM 的分类表达式为:

$$y(\mathbf{x}) = \text{sign} \left[\sum_{i=1}^m \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \right] \quad (3)$$

式中: \mathbf{x} 为 DBN 提取出的轨道电路故障特征向量; $K(\mathbf{x}, \mathbf{x}_i)$ 为核函数, 本文选择径向基核函数, 其定义式为式 (4), 其中 σ^2 为核函数参数。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2) \quad (4)$$

惩罚因子 γ 控制对超出误差样本的惩罚误差, γ 越大, 其适应性越强, 容易出现过拟合; γ 越小, 模型复杂度越低, 容易出现欠拟合。核函数参数 σ^2 影响输出空间的维度大小。海洋捕食者算法是 2020 年提出的群体智能算法^[14], 其灵感来源于海洋适者生存理论, 具有寻优能力更强、速度更快等特点, 本文引用 MPA 获取 LSSVM 最优惩罚因子和核函数参数 $[\gamma_{best}, \sigma_{best}^2]$, 其基本流程如下:

步骤 1) 初始化 MPA 算法的参数, 其中包括种群大小 n , 最大迭代次数 Max_Iter 、鱼类聚集装置效应系数

$FADs$, 以及惩罚因子和核函数参数的优化范围。

步骤 2) 结合故障特征训练集, 以 LSSVM 模型的分类准确率作为适应度函数, 获取被捕食者初始位置并计算适应度值。

步骤 3) 分别从迭代初期、迭代中期、迭代后期进行迭代优化, 更新猎物位置。然后计算新位置的适应度, 并根据鱼类聚集装置或涡流效应对适应度值的影响进行评估, 根据猎物位置和行为计算最佳捕食者位置, 最终确定并存储当前最优位置。

步骤 4) 判断 $iter \geq Max_iter$ 是否成立, 如果不满足终止条件, 继续重复步骤 2) ~ 3) 寻找最优解; 否则终止计算, 输出最优参数集合 $[\gamma_{best}, \sigma_{best}^2]$ 。

步骤 5) 将 MPA 全局最优参数组合 (惩罚因子 γ 和核函数参数 σ^2) 赋值给 LSSVM 模型, 进行轨道电路的故障类型识别分类。

2 ZPW-2000 无绝缘轨道电路

区间 ZPW-2000 无绝缘轨道电路由室内外设备构成, 其组成结构如图 2 所示。其室内设备有发送器、接收器、衰耗冗余控制器、电缆模拟网络、站防雷、通信接口板、监测维护系统、分线采集器; 其室外设备有: 钢轨、调谐匹配变压器、空心线圈、补偿电容、SPT 传输电缆等^[15]。

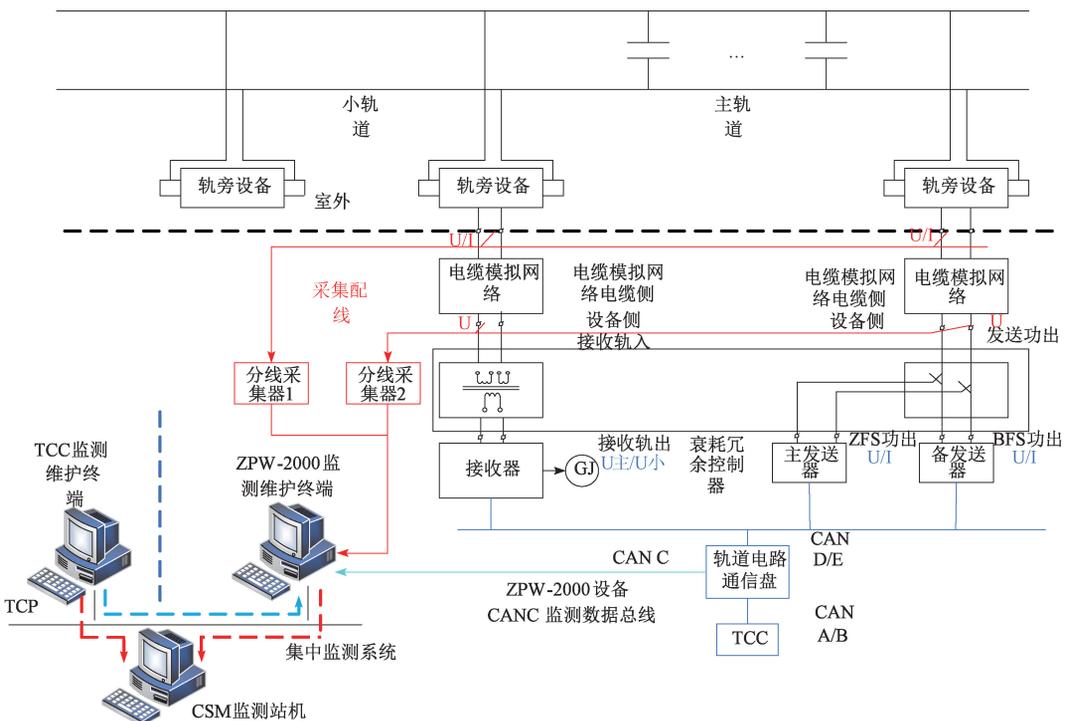


图 2 ZPW-2000 无绝缘轨道电路结构示意图

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

本文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诊断。ZPW-2000 轨道电路常见的故障类别^[16]及故障影响归纳如表 1 所示。

表 1 轨道电路典型故障模式

Table 1 Typical failure modes of track circuit

故障编号	故障类别
F1	正常
F2	发送器故障
F3	发送端调谐匹配单元故障
F4	主轨故障
F5	接收端调谐匹配单元故障
F6	小轨故障
F7	衰耗冗余控制器故障
F8	分线采集器故障
F9	接收器故障

3 DBN-MPA-LSSVM 故障诊断网络设计

3.1 数据获取

本实验利用某铁路局提供的轨道电路集中监测数据进行实验验证,选择集中监测系统中 14 个监测参数作为数据集的输入,监测数示意如表 2 所示。采用 DBN 算法对以上各电压量、电流参数变化情况进行故障特征信息的提取,从而为判断轨道电路的故障类型提供特征依据^[17]。

表 2 监测参数示意

Table 2 Schematic diagram of monitoring parameters

序号	监测参数	单位	标准值
1	发送电源电压 C_1	V	$[24 \pm 1]$
2	功出电压 C_2	V	$[73, 181]$
3	功出电流 C_3	mA	$[200, 500]$
4	主轨道输入电压 C_4	mV	≥ 170
5	小轨道输入电压 C_5	mV	≥ 42
6	轨出 1 电压 C_6	mV	≥ 240
7	轨出 2 电压 C_7	mV	$[100, 145]$
8	GJ 电压 C_8	V	≥ 24 V
9	XG 电压 C_9	V	≥ 24 V
10	XGJ 电压 C_{10}	V	≥ 24 V
11	分线盘送端 电缆侧电压 C_{11}	V	\leq 功出电压
12	分线盘送端 设备侧电压 C_{12}	V	\approx 功出电压
13	分线盘受端 电缆侧电压 C_{13}	V	\geq 防雷变压器电压
14	分线盘受端 设备侧电压 C_{14}	V	\approx 轨入电压

3.2 数据预处理

由于集中监测数据各参数物理意义不同,量纲也不相同,为了提高模型的分类准确性和运行效率,对特征样本进行归一化预处理,将样本数据归一化至 $[0, 1]$ 之间,归一化公式如下:

$$y = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (5)$$

式中: x 为原始数据; y 为归一化之后的数据。

3.3 诊断模型结构设计

DBN 模型的输入为不同故障模式下的 14 维故障数据集,输出为 9 种故障类型,对应 F1~F9,选用 MPA 优化的 LSSVM 作为网络顶层的输出分类器。对 DBN 影响最大的因素包括隐藏层层数以及每层神经元节点数目,目前用于确定隐藏层层数和节点数的理论方法尚未成熟^[18],本文选择经验法和试凑法来确定 DBN 隐藏层层数和节点数,选取最佳参数组合。

3.4 DBN-MPA-LSSVM 诊断流程

基于 DBN-MPA-LSSVM 的具体诊断步骤描述如下,诊断流程如图 3 所示。

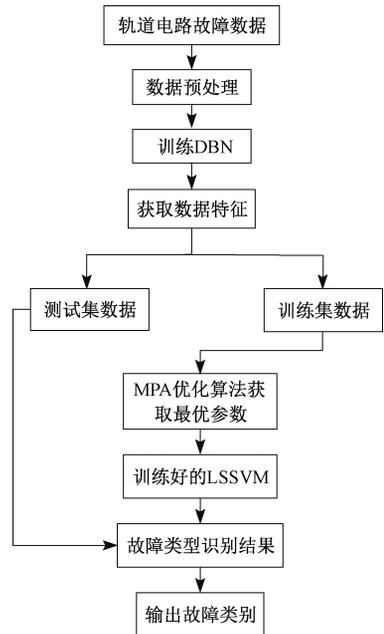


图 3 DBN-MPA-LSSVM 诊断流程

Fig. 3 DBN-MPA-LSSVM diagnosis flow chart

步骤 1) 获取无绝缘轨道电路集中监测系统中的监测参数,形成故障数据集,并对数据集进行归一化处理;

步骤 2) 采用 DBN 对故障数据集进行降维和故障特征提取,学习率设置为 0.01,迭代次数为 50 次;

步骤 3) 将故障特征样本数据分为训练集和测试集;

步骤 4) 结合训练集特征数据,引入智能算法 MPA

对 LSSVM 的惩罚因子 γ 和核函数参数 σ^2 进行全局寻优,MPA 种群大小 $n = 20$, $Max_Iter = 50$, $FADs$ 设置为 0.2,参数 $[\gamma, \sigma^2]$ 的取值范围为(0.001,100);

步骤5)将 MPA 寻找的最优参数赋值给 LSSVM 的惩罚因子和核函数参数进行网络训练,将测试集输入到训练后的 LSSVM 分类器中进行故障分类,输出识别结果。

4 实验仿真结果分析

4.1 故障特征数据集

将轨道电路数据样本划分为训练集和测试集,训练集数据每种故障类型取 50 组,共有 450 组故障数据,测试集数据每种故障类型取 20 组,共有 180 组故障数据,故障代码均为 F1~F9。本实验采用 MATLAB 2021a 和 libsvm 工具箱编写相关程序并完成仿真实验。

4.2 DBN 模型参数确定

深度置信网络在训练的过程中其结果受隐藏层层数和节点数影响较大,因此对以上两个参数需用科学方法来确定。根据诊断模型中系统输入为 14 维特征向量,输出为 9 种故障类型,因此设置第 1 个可见层节点数为 14,输出层节点为 9。对于隐藏层神经元个数选择参考文献 [19] 中的经验公式: $I = \sqrt{m + n} + \alpha$, 其中 m 为输入层节点数, n 为输出层节点数, α 为 $[0, 10]$ 之间的常数。确定出节点数的大致范围是 $[5, 15]$ 。依次选取不同节点数进行仿真实验,其分类效果如图 4 所示。从图 4 中可以看出,当隐藏层节点选取为 15 时,识别准确率为 94.66%,因此 DBN 隐藏层节点设置为 15。

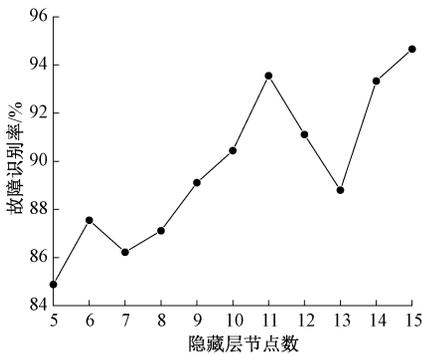


图 4 不同隐藏层节点数 DBN 分类能力
Fig. 4 DBN classification ability of nodes in different hidden layers

隐藏层层数的增加在一定程度上可以提高精度,但层数过多会产生过拟合,且训练时间较长。本文对于不同层数的 DBN 分类结果如表 3 所示。

表 3 不同隐藏层结构 DBN 分类能力

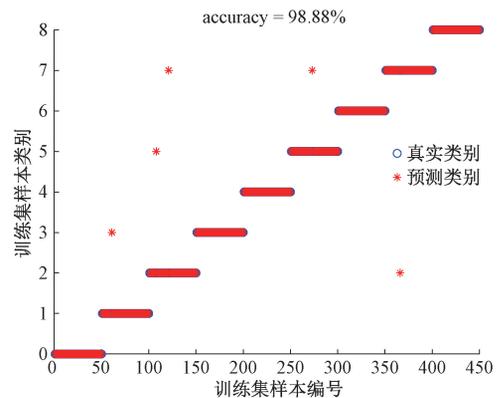
Table 3 Classification ability of DBN with different hidden layer structures

DBN 结构	平均故障识别准确率/%	训练时间/s
14-15-9	94.66	27.528
14-15-15-9	95.33	41.235
14-15-15-15-9	98.88	52.543
14-15-15-15-15-9	82.22	79.634

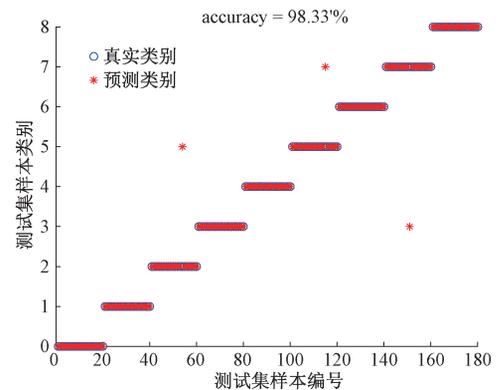
从表 3 中可以看出,当 DBN 层数为 5 层时故障识别准确率最高,当层数大于 5 时,其故障识别准确率降低,发生了过拟合。因此通过上述实验结果选取 DBN 网络结构为 14-15-15-15-9。

4.3 DBN-MPA-LSSVM 故障诊断结果

以训练集和测试集的分类准确率作为模型的评价标准,设置最大迭代次数为 50,对 DBN-MPA-LSSVM 诊断模型进行训练,其优化后的最佳参数为惩罚因子 Best $\gamma = 65.8395$,核函数参数 Best $\sigma^2 = 0.1406$ 。不同故障模式下的训练集和测试集识别准确率如图 5 所示。



(a) 训练集 MPA-LSSVM 分类结果
(a) Classification results of training set MPA-LSSVM



(b) 测试集 MPA-LSSVM 分类结果
(b) Classification results of test set MPA-LSSVM

图 5 训练集和测试集故障诊断结果

Fig. 5 Fault diagnosis results of training set and test set

分析图 5 可知,训练集中有 5 个样本被错误分到了其他类别,故障识别准确率达到 98.88%,测试集诊断结果中仅第 2 类、第 5 类、第 7 类共 3 个错误数据,分别被错误识别为第 5 类、第 7 类和第 3 类故障,故障识别准确率为 98.33%,可见本文所提出的诊断方法具有较高的分类精确度。为进一步验证 DBN-MPA-SVM 模型的整体效果,将本文模型与其他故障诊断模型在测试集进行对比分析,包括支持向量机(support vector machine, SVM)、主成分分析(principal component analysis, PCA)。PCA 可以去掉原始数据中的冗余信息,使得数据结构更加简单。不同诊断模型识别结果如表 4 所示,其中 SVM 与 LSSVM 模型输入均未经过特征提取。

表 4 不同诊断模型准确率对比
Table 4 Comparison of accuracy of different diagnostic models

诊断模型	准确率/%	时间/s
LSSVM	88.44	25.60
SVM	85.55	36.80
DBN	91.66	63.28
DBN-LSSVM	92.77	93.64
PCA-LSSVM	90.00	56.82
DBN-MPA-LSSVM	98.33	81.54

从表 4 中可以看出,轨道电路原始数据在未经特征提取作为输入的 SVM 和 LSSVM 模型中,准确率均低于 90%,诊断效果不佳,且 LSSVM 较 SVM 缩短了诊断时间;DBN 发挥了良好的特征提取能力,较 PCA 提取性能有所提高;采用 MPA 优化的 DBN-LSSVM 诊断模型分类准确率最高,训练时间为 81.54 s,能够通过集中监测数据特征提取进而完成故障模式识别,实现轨道电路故障诊断。

为了进一步验证本文所用 MPA 算法对于 LSSVM 参数优化的优越性,将粒子群(particle swarm optimization, PSO)、灰狼(grey wolf optimizer, GWO)、遗传算法(genetic algorithm, GA) 3 种智能算法分别设置为 DBN 顶层分类器模型,并将其输出结果与 MPA-LSSVM 进行比较。所有实验中,各种群大小设置为 20,最大迭代次数设置为 50,惩罚因子和核函数参数的取值范围均为 (0.001, 100)。其中 PSO 的惯性权重设置为 1,加速度系数 c_1 和 c_2 设置为 2;GA 的交叉和变异概率设置为 [0.8, 0.02]。PSO-LSSVM、GWO-LSSVM、GA-LSSVM、MPA-LSSVM 四种模型的分 类准确率如表 5 所示,适应度曲线如图 6 所示。

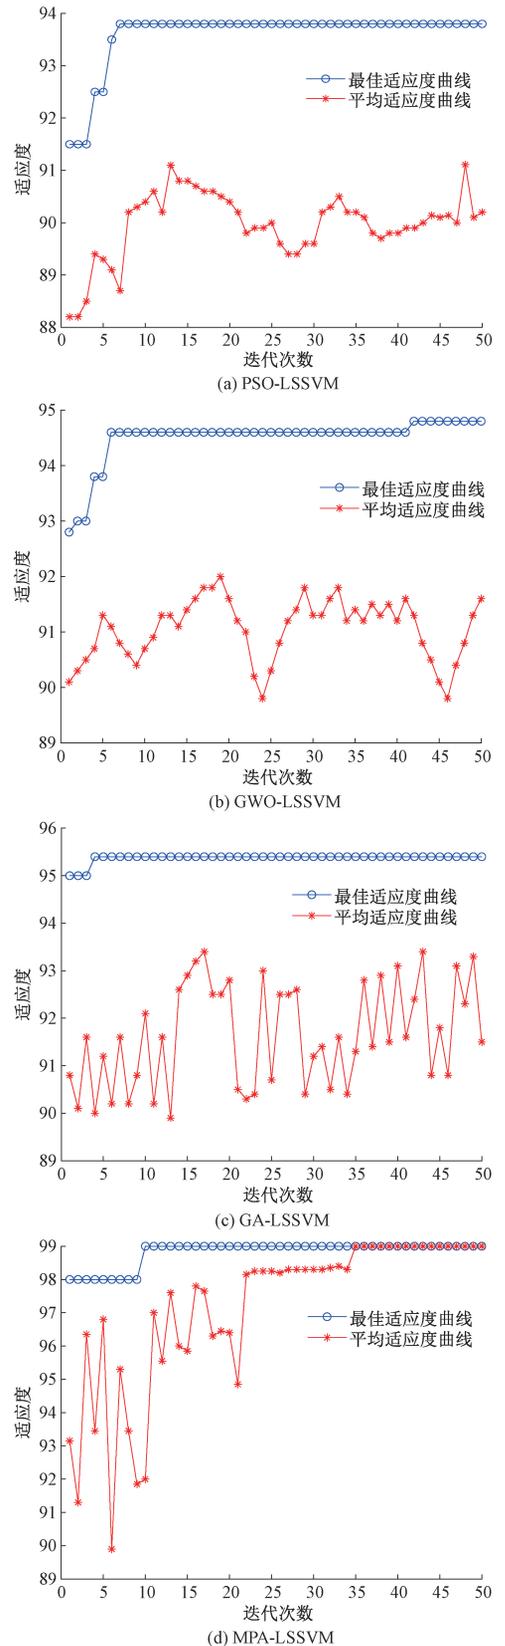


图 6 不同算法优化 LSSVM 的优化过程
Fig. 6 Different algorithms optimize the optimization process of LSSVM

表 5 不同算法优化 LSSVM 的比较

Table 5 Comparison of LSSVM optimized by different algorithms

模型	测试集准确率/%	Best γ	Best σ^2
PSO-LSSVM	92.22	35.795 8	1.873 2
GWO-LSSVM	94.44	74.593 1	0.681 2
GA-LSSVM	95.00	82.164 4	6.687 4
MPA-LSSVM	98.33	65.839 5	0.140 6

从表 5 可以看出,MPA-LSSVM 模型测试集诊断准确率分别高于 PSO-LSSVM、GWO-LSSVM、GA-LSSVM 模型 6.11%、3.89%、3.33%。分析图 6 可知,随着迭代次数的增加,MPA-LSSVM 的最佳适应度值(训练集的分类准确率)达到了 4 种模型的最大值;在迭代初期,MPA 的种群平均适应度就高于其他 3 种优化算法,并且随着迭代次数的增加,MPA 的种群平均适应度进化趋向于更高的适应度值,而 PSO-LSSVM、GWO-LSSVM、GA-LSSVM 模型的种群平均适应度值均出现不规则波动,种群的进化趋势明显劣于 MPA。分析原因可知,MPA 独特的搜索机制有助于种群的更高级进化,随着迭代次数逐渐增加,在优化后期几乎所有捕食者都聚集在猎物附近。相比之下,PSO 算法、GWO 算法和 GA 算法由于无法跳出局部最优,其优化后的 LSSVM 模型分类准确率低于 MPA-LSSVM 算法。

由于优化算法对 LSSVM 参数的寻优具有随机性,因此通过 10 次重复实验来验证模型的有效性。图 7 记录了 4 种不同模型在相同测试条件下每一次分类准确率的大小。从图 7 中可以看出,本文所提出 MPA-LSSVM 诊断模型在 10 次实验中平均分类准确率明显高于 PSO-LSSVM、GWO-LSSVM、GA-LSSVM,且具有更高的稳定性,其平均分类准确率达到 97.98%,结果验证了 DBN-MPA-LSSVM 诊断模型的有效性和可行性。

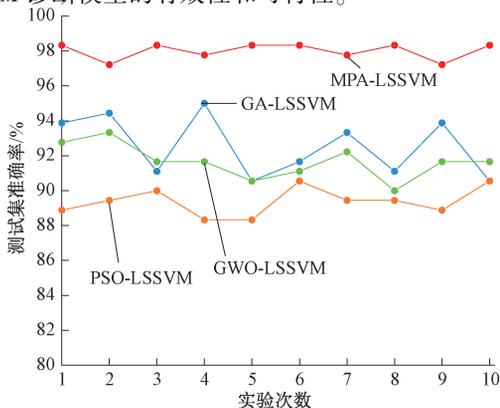


图 7 不同优化算法诊断模型重复实验结果对比

Fig. 7 Comparison of repeated experimental results of diagnosis models with different optimization algorithms

5 结论

针对区间无绝缘轨道电路故障类型复杂、诊断精度低等问题,结合信号集中监测系统采集到的室内外设备电气参数,提出了基于 DBN 特征提取和 MPA-LSSVM 分类的故障诊断方法,主要结论如下:

1) DBN 通过无监督深度特征学习,获取轨道电路故障特征变化。结合最小二乘支持向量机作为顶层分类器模型,实现了轨道电路多维故障模式识别。

2) DBN-MPA-LSSVM 提高了故障识别准确率,缩短了支持向量机的工作时间。此外,经过重复实验验证,使用 MPA 优化的 LSSVM 诊断模型准确率高,收敛速度快,能够有效避免陷入局部极值。与 PSO、GWO、GA 优化算法相比,MPA 增强了优化效果,以更低的计算成本获得了优于其他 3 种方法的解。在训练集为 450,测试集为 180 的条件下,基于 DBN-MPA-LSSVM 模型的平均分类准确度达到了 97.98%,达到了更好的故障诊断效果,为轨道电路故障诊断提供了一种新的智能方法。

参考文献

[1] 燕飞,唐涛. 轨道交通信号系统安全技术的发展和现状[J]. 中国安全科学学报,2005(6):94-99,113.
YAN F, TANG T. Development and research status of safety technology of rail transit signal system [J]. Chinese Journal of Safety Science, 2005(6):94-99,113.

[2] 夏齐林. 信号集中监测系统功能优化及应用[J]. 上海铁道科技,2018(3):155-156.
XIA Q L. Function optimization and application of centralized signal monitoring system [J]. Shanghai Railway Technology, 2018(3):155-156.

[3] 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.

[4] 王秋实. ZPW-2000A 型无绝缘移频轨道电路智能故障诊断方法研究[D]. 成都:西南交通大学,2017.
WANG Q SH. Research on intelligent fault diagnosis method of ZPW-2000A jointless frequency shift track circuit [D]. Chengdu: Southwest Jiaotong University, 2017.

[5] 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 area of jointless track circuit based on improved convolutional neural network [J]. Railway Computer Application, 2020,29(6):58-63,74.

- [6] 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 Railway, 2021, 43 (5): 104-111.
- [7] 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. Research on 25 Hz phase sensitive track circuit fault diagnosis based on bat algorithm optimized fuzzy neural network [J]. Journal of Railways, 2018, 40 (12): 93-100.
- [8] BRUIN T D, VERBERT K, BABUKA R. Railway track circuit fault diagnosis using recurrent neural networks [J]. IEEE Transactions on Neural Networks & Learning Systems, 2016, 28 (3): 523-533.
- [9] 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 Railway, 2020, 42 (6): 79-85.
- [10] 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. Fault diagnosis of track circuit based on adaptive mutation SAPSO-LSSVM [J]. Journal of Beijing Jiaotong University, 2021, 45 (2): 1-7.
- [11] TAIBI A, IKHLEF N, TOUATI S. A novel intelligent approach based on WOAGWO-VMD and MPA-LSSVM for diagnosis of bearing faults [J]. The International Journal of Advanced Manufacturing Technology, 2022, 120 (5-6): 3859-3883.
- [12] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18 (7): 1527-1554.
- [13] 邓勇,蒋田,赖治屹. 基于 DBN 和 LSSVM 的管道气体压力检测方法研究 [J]. 电子测量与仪器学报, 2021, 35 (6): 198-204.
DENG Y, JIANG T, LAI ZH Y. Research on pipeline gas pressure detection method based on DBN and LSSVM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (6): 198-204.
- [14] FARAMARZI A, HEIDARINEJAD M, MIRJALILI S, et al. Marine predators algorithm: A nature-inspired metaheuristic [J]. Expert Systems with Applications, 2020, 152: 113377.
- [15] 张才林. 基于神经网络的无绝缘轨道电路调谐区故障诊断方法的研究 [D]. 北京: 北京交通大学, 2013.
ZHANG C L. Research on fault diagnosis method of tuning area of uninsulated track circuit based on neural network [D]. Beijing: Beijing Jiaotong University, 2013.
- [16] 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 Railways, 2018, 40 (7): 74-79.
- [17] 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.
LI W H. Principle, Maintenance and Troubleshooting of ZPW-2000A Frequency Shift Automatic Block System [M]. Beijing: China Railway Press, 2010.
- [18] 杨大炼,张帆宇,李仁杰,等. DBN 参数对双转子不对中故障特征提取的影响及综合评估优选研究 [J]. 振动与冲击, 2021, 40 (12): 151-158.
YANG D L, ZHANG F Y, LI R J, et al. Influence of DBN parameters on dual rotor misalignment fault feature extraction and comprehensive evaluation of preferential selection study [J]. Vibration and Shock, 2021, 40 (12): 151-158.
- [19] SHAO H, JIANG H, ZHANG X, et al. Rolling bearing fault diagnosis using an optimization deep belief network [J]. Measurement Science and Technology, 2015, 26 (11): 115002.

作者简介



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 an associate professor in Lanzhou Jiaotong University. His main research interests include train operation control system fault diagnosis and railroad communication technology research.



王帅, 2020 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: 1229609925@qq.com

Wang Shuai received his B. Sc. degree from Lanzhou Jiaotong University in 2020. Now he is a M. Sc. candidate in the School of Automation and Electrical Engineering of Lanzhou Jiaotong University. His main research interest includes rail circuit fault diagnosis.