

高速列车牵引变流器故障诊断研究*

顾佳^{1,3}, 黄明², 关岳⁴

(1. 大连交通大学机械工程学院 大连, 116028) (2. 大连交通大学软件学院 大连, 116028)

(3. 中车青岛四方机车车辆股份有限公司信息技术部 青岛, 266111)

(4. 中车青岛四方机车车辆股份有限公司国家工程试验室 青岛, 266111)

摘要 针对高速列车牵引变流器冷却滤网状态异常引发的牵引变流器故障问题,通过综合分析牵引变流器故障分类和滤网堵塞程度之间的相关性,提出一种基于多任务深度学习的故障诊断方法。首先,构建了包含牵引变流器故障诊断主任务及滤网堵塞程度子任务的多任务深度神经网络(multi-task deep neural networks,简称 MT-DNN);然后,为了准确预测牵引变流器失效退化趋势,将多任务深度神经网络预测结果与自组织映射(self organizing map,简称 SOM)方法结合,构建了多任务深度神经网络自组织映射模型(multi-task deep neural networks self-organizing map,简称 MTDNN-SOM),该方法根据历史故障数据特征变量演化规律定义退化状态曲线,直接反映故障特征量和退化状态之间的关系,最终实现了牵引变流器滤网脏堵故障诊断和维修预测。试验结果表明,该方法在精度和效率上都明显优于单任务或传统故障诊断方法,得到了较好的效果。

关键词 高速列车; 牵引变流器; 故障诊断; 多任务深度神经网络; 自组织映射

中图分类号 TH165.3

引言

牵引变流器作为高速列车的关键部件,主要作用是实现电能的转换。牵引变流器会在列车行驶过程中会产生大量的热量,为保证牵引变流器正常工作,这些热量将被冷却系统通过水冷或风冷的方式带走。风冷即冷却风机通过从外部抽入冷却空气作用在散热器上,以达到冷却的目的,冷却系统滤网的作用是阻挡空气中的尘埃粒子以及较大的颗粒污染物进入冷却系统。随着列车的持续运行,滤网上吸附的灰尘越来越多,通风量越来越少,冷却效果随之也会变得越来越差。当滤网堵塞到一定程度,冷却系统不能满足实际要求时,会导致牵引变流器过热引起安全问题,对动车组的正常运行造成极大的影响。随着季节、运行线路环境的不同,滤网堵塞程度也不相同,应适时清理滤网沉积物,以免影响牵引变流器的正常运行。

目前,动车组对于牵引变流器滤网的清洁采取计划修的方式。这种维修方式能够在一定程度上避免牵引变流器滤网堵塞,但存在过度维修、浪费维修

资源问题,对于一些短时间发生严重堵塞的情况也会存在欠修风险。牵引变流器滤网清理状态修是运用列车车载状态数据、故障数据、环境工况数据以及检修运用数据,利用数据分析挖掘和人工智能等方法,通过研究滤网堵塞与牵引变流器故障、冷却系统水温变化及新风温度等因素之间的关系,构建滤网堵塞故障诊断模型。同时,利用滤网堵塞故障诊断模型提取的多维故障特征,拟合出滤网堵塞退化状态曲线,来表征滤网健康水平的退化状态或退化程度,并依据退化趋势来预测滤网清洁的维修时间,动态判定滤网是否需要进行清理,以及何时需要清理。

近些年,基于机器学习的故障诊断方法已成为研究热点^[1],例如:支持向量机(support vector machine,简称 SVM)和 BP 神经网络(back propagation neural network,简称 BPNN)等^[2]。然而,以上浅层学习模型用于故障诊断时,诊断精度依赖于提取故障特征的好坏,且在多维大数据情况下,其诊断效果和泛化能力明显不足。深度学习作为机器学习的一个分支,具有强大的建模能力,在故障诊断等领域同样取得较好的研究成果。深度学习通过逐层特征提取,能够学习出故障的早期特征,相比浅层的机

* 工信部智能制造综合标准化与新模式应用资助项目(2017ZNZZ01)

收稿日期:2020-04-16;修回日期:2020-05-10

器学习算法有更好的优势^[3-6]。然而,单任务深度学习在实际应用中通常会遇到训练样本不充分以及欠拟合的问题,相关任务之间的关联关系没有被进一步挖掘,模型的泛化能力不强。

视情维修的核心是对设备的退化状态进行建模及对剩余寿命进行预测。通过对退化状态建模可以实时了解设备从健康状态转变为当前退化状态的变化情况,剩余寿命预测可以为设备的维修决策提供指导作用^[7]。在传统方法中,特征提取能力和非线性函数映射能力逐渐暴露出不足,迫切需要利用新的智能学习方法对设备进行更加精准、高效的退化状态建模。近些年,深度学习凭借强大的特征提取能力和非线性函数映射能力,逐渐成为设备退化状态建模领域的研究热点。

笔者利用已收集的故障样本数据,运用多任务深度学习,综合考虑滤网故障分类诊断和滤网堵塞严重程度预测 2 个相关任务,通过训练样本对多个具有共享表达的任务进行并行学习,将其他任务学到的知识用于目标任务中,从而提升目标任务效果。首先,利用列车实时采集的牵引变流器状态数据、故障样本数据构建牵引变流器滤网堵塞故障诊断主任务;其次,利用列车回库检修过程中采集到的人工测量数据,构建滤网堵塞严重程度辅助子任务,在深度神经网络(deep neural networks,简称 DNN)基础上,通过共享 2 个任务的输入参数,构建了牵引变流器滤网多任务深度神经网络诊断模型;然后,结合 SOM 方法将多任务深度学习所抽取的高维故障特征向量集成为一个故障特征变量,根据历史故障数据特征变量演化规律,拟合退化状态曲线,直接反映故障特征量和退化状态之间的关系,实现滤网堵塞维修决策。

1 多任务深度学习和自组织映射

1.1 多任务深度学习

多任务学习(multi-task learning,简称 MTL)通过对训练样本中选择 2 个以上训练目标,并根据目标间相关性提升模型训练的泛化性能的方法^[8]。多任务学习与单任务学习(single-task learning,简称 STL)相比,MTL 通过利用多个任务之间的相关信息来提升任务之间的辨识度或预测能力,即 MTL 通过放松部分训练样本与主任务之间的关系,同时,相关任务利用潜在数据特征提升模型训练效果,从而实现模型的泛化能力。目前,MTL 主要

解决图像识别和语音识别等问题^[9-10]。

与单任务深度神经网络(single-task deep neural networks,简称 ST-DNN)相比,多任务深度神经网络采用多个任务共享同一隐层的方式,每个隐层的输出将作为多个任务输入。MT-DNN 通过多任务共享隐层的机制,可以有效提取任务之间的共同信息,克服由于训练样本不足而导致的网络训练不足^[11]。

多任务联合训练过程如下: T 为总任务数, $(\mathbf{x}_i^t, \mathbf{y}_i^t)$ 为第 t 个任务的训练样本数据。其中: $t \in (1, 2, \dots, T)$; $i \in (1, 2, \dots, N)$; N 为总训练样本数; $\mathbf{x}_i^t, \mathbf{y}_i^t \in \mathbf{R}$, 分别为第 i 个样本的特征向量和标注标签。多任务目标函数可以表示为

$$\operatorname{argmin}_{\{\mathbf{w}^t\}_{t=1}^T} \sum_{t=2}^T \sum_{i=1}^N L(\mathbf{y}_i^t, f(\mathbf{x}_i^t; \mathbf{w}^t)) + \lambda \varphi(\mathbf{w}^t) \quad (1)$$

其中: $f(\mathbf{x}_i^t; \mathbf{w}^t)$ 为输入特征向量 \mathbf{x}_i^t 和权重参数 \mathbf{w}^t 的映射函数; $L(\cdot)$ 为式(1)的损失函数; $\varphi(\mathbf{w}^t)$ 为权重参数的正则化值; λ 为正则化系数因子。

1.2 自组织映射

自组织映射作为一种无监督竞争式机器学习算法^[12],主要作用是将任意维度的输入通过权值计算转变为一维或者二维的离散映射,权值计算的过程满足自适应的特点^[13]。SOM 学习算法步骤如下:

1) SOM 网络的初始化。选择权值较小的随机值对输入向量和权值进行初始化,并对输入向量和权值做归一化处理。

2) SOM 神经网络的向量输入。将输入向量 $\mathbf{X} = \{x_1, x_2, \dots, x_m\}^T$ 按照对应的维度赋值给各个输入神经元。

3) 确定输入向量与权值向量的欧几里得距离。距离最小的神经元将赢得竞争,以权值向量的第 j 神经元的计算为例,计算其与输入向量间的距离

$$d_j \|\mathbf{X} - \mathbf{W}_j\| = \sqrt{\sum_{i=1}^m (x_i(t) - w_{ij}(t))^2} \quad (2)$$

其中: w_{ij} 为输入向量的 i 神经元和权值向量的 j 神经元之间的权值。

通过计算并比较距离值,与权值向量中距离最小的神经元称为胜出神经元,记为 j^* 。根据 j^* 确定出某个处理单元 k ,该单元对于任意的 j 满足 $d_k = \min_j(d_j)$,据此确定相应的邻接神经元集合。

4) 权值的学习。调整式(2)中所确定的胜出神经元 j^* 及其邻接神经元的权值

$$\Delta w_{ij} = w_{ij}(t+1) - w_{ij}(t) = \eta(t)(x_i(t) - w_{ij}(t)) \quad (3)$$

其中: η 为常数, $0 < \eta < 1$, 随时间变化 η 衰减为 0。

$$\eta(t) = \frac{1}{t} \quad (4)$$

5) 确定输出 o_k

$$o_k = f(\min\|\mathbf{X} - \mathbf{W}_j\|) \quad (5)$$

其中: $f(*)$ 为输出函数, 其输出值为 $0 \sim 1$, 且 $f(*)$ 可以为其他的非线性函数。

6) 判断是否收敛。如果满足设定的迭代次数要求, 算法结束; 否则, 返回步骤 2, 继续学习。

2 牵引变流器滤网堵塞故障诊断及维修预测模型

2.1 牵引变流器滤网堵塞故障诊断

利用多任务深度学习进行牵引变流器滤网堵塞故障诊断包括以下几个步骤。

1) 构建一个含有 N 个隐层、2 个任务的多任务深度神经网络, 图 1 为基于 DNN 的多任务学习模型。网络架构为

[DNNnet] =

Feedforward($\mathbf{X}; H_1, H_2, \dots, H_N; \mathbf{Y}^{\text{main}}, \mathbf{Y}^{\text{sub}}; \mathbf{W}, \mathbf{b}$)

其中: $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$; $\mathbf{x}_i = \{x_{i1}, x_{i2}, \dots, x_{id}\}^T$ 为输入样本; N 为样本数; $\mathbf{Y}^{\text{main}} = \{y_1^{\text{main}}, y_2^{\text{main}}, \dots, y_N^{\text{main}}\}$ 为主任务滤网堵塞故障诊断模型的样本标签; y_i^{main} 为每个样本的期望值 0 或 1; $\mathbf{Y}^{\text{sub}} = \{y_1^{\text{sub}}, y_2^{\text{sub}}, \dots, y_N^{\text{sub}}\}$ 为子任务滤网脏堵严重程度模型的样本标签, 取值为通风风速数值; \mathbf{W} 为权值矩阵; \mathbf{b} 为偏置向量; H_1, H_2, \dots, H_N 为隐层神经元个数; 网络初始化参数为 $\mathbf{W} = \text{random_uniform}()$, $\mathbf{b} = \text{zero}()$ 。

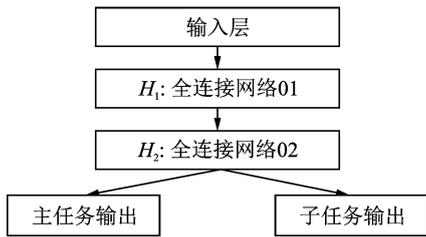


图 1 基于 DNN 的多任务学习模型

Fig. 1 Multi-task learning model based on DNN

2) 构造滤网堵塞故障诊断主任务和滤网堵塞严重程度子任务, 2 个任务共享 DNN 隐层 H_1, H_2 特征, 在隐层 H_2 添加 2 个输出, 主任务输出表示滤网堵塞故障诊断, 为二分类问题; 子任务输出表示滤网堵塞严重程度, 为回归问题。其中: 主任务激活函数和子任务激活函数采用 sigmoid; 主任务损失函数

采用二分类交叉熵; 子任务损失函数采用均方误差。

3) 计算模型总的损失函数为

$$J = \alpha J_{\text{main}} + \beta J_{\text{sub}} \quad (\alpha = 1, \beta = 1) \quad (6)$$

其中

$$J_{\text{main}} = - \sum_{i=0}^n \bar{y}_i \log y_i + (1 - \bar{y}_i) \log(1 - \bar{y}_i) \quad (7)$$

$$J_{\text{sub}} = \sum_{i=0}^n (y_i - \bar{y}_i)^2 \quad (8)$$

$$\frac{\partial J_{\text{main}}}{\partial y} = - \sum_{i=0}^n \frac{\bar{y}_i}{y_i} - \frac{1 - \bar{y}_i}{1 - y_i} \quad (9)$$

$$\frac{\partial J_{\text{sub}}}{\partial y} = 2 \sum_{i=0}^n (y_i - \bar{y}_i) \quad (10)$$

4) 多任务模型训练。上述 2 个任务通过总的损失函数 J 立, 通过最小化误差函数 J 用梯度下降法来更新网络参数, 公式为

$$\mathbf{W}_{jk}^{(l)} = \mathbf{W}_{jk}^{(l)} - \eta \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{W}_{jk}^{(l)}} \quad (11)$$

$$\mathbf{b}_j^{(l)} = \mathbf{b}_j^{(l)} - \eta \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{b}_j^{(l)}} \quad (12)$$

其中: $\eta > 0$, 为学习速率, 笔者使用随机梯度下降优化 (stochastic gradient descent, 简称 SGD) 算法来求解总的目标函数式的最小值。

2.2 牵引变流器滤网堵塞性能退化曲线拟合

利用提取到的牵引变流器滤网堵塞故障特征进行滤网堵塞性能退化预测, 图 2 为牵引变流器故障诊断及状态修预测方法流程图。

1) 将提取出的多个特征作为 SOM 网络的输入, SOM 网络的输入层节点数与特征数一致。设置相关网络参数后进行训练, 拓扑层的神经元数为 d , 最大训练次数为 T , 通常拓扑层的神经元个数取为 $D = 5\sqrt{M}$, M 为输入样本数^[14]。

2) 计算拓扑层中所有 d 个神经元的向量与输入层样本 \mathbf{x}_k 的欧式距离 \mathbf{d}_k , 选择与 \mathbf{x}_k 距离最小的神经元作为最佳匹配神经元 c , 即 $\|\mathbf{x}_k - \mathbf{w}_c\| = \min\{\mathbf{d}_k\}$, \mathbf{w}_c 为最佳匹配神经元的向量表征。令最小量化误差 (minimum quantifying error, 简称 MQE)^[15] $\text{MQE} = \|\mathbf{x}_k - \mathbf{w}_c\|$, 定义为样本 \mathbf{x}_k 在该时刻的相对堵塞率。

3) 将包含从滤网刚被清洁到由于堵塞而引起故障整个周期的滤网堵塞故障样本数据作为测试数据, 输入到训练好的多任务深度神经网络中, 通过多个隐含层和分类、回归进行特征提取, 之后将提取出的特征输入到训练好的 SOM 网络, 构建滤网堵塞性能退化曲线。

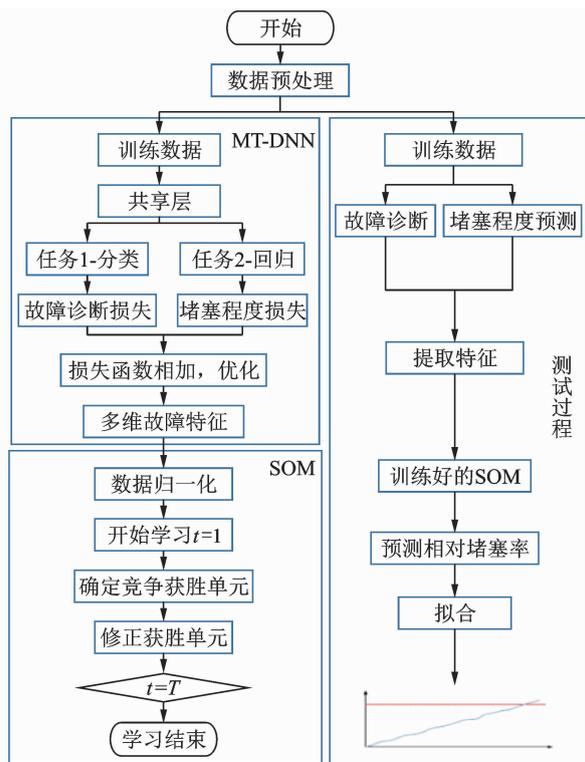


图2 牵引变流器故障诊断及状态修预测方法流程图

Fig. 2 Flow chart of fault diagnosis and condition-based maintenance prediction model for traction converter

3 试验结果与分析

3.1 故障样本分析及指标选择

选择某列车实际故障样本数据进行分析,排除其他因素干扰,笔者选择列车在正常运行过程中,其他条件恒定的情况下观察滤网堵塞情况与牵引变流器水温温度变化的关系。恒定条件为:时速大于300 km/h;风机转速为高速;风机电流正常;进、出水口压力正常。

在列车运行过程中的46 d时间内共进行3次周期性滤网堵塞清理工作。从第1次清理到第2次清理时隔25 d,在此期间随着时间的推移,进、出水口温度越来越高,到第26 d时报高温故障,现车检查牵引变流器风机滤网脏堵严重,散热器表面有灰尘,对比其他车透光性差,当天进行清理。第2次清理到第3次清理时隔20 d,温度变化与上一次相似,第20 d报高温故障,库内检查牵引变流器滤网轻微脏堵,当日进行清理,第1个滤网堵塞周期进、出水口温度变化如图3所示。

分析发现,水温温度变化是一个周期性的变化过程,跟滤网清理周期关系很大。滤网清理后随着

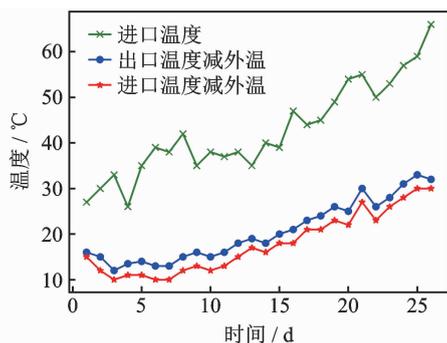


图3 牵引变流器滤网堵塞与进、出水口温度的关系

Fig. 3 The relationship between the filter blockage of the traction converter and the temperature of the inlet and outlet

时间的推移,滤网表面附着的灰尘越来越多,导致滤网脏堵越来越严重,影响冷却系统散热,从而导致进、出水口的温度越来越高。

除变流器冷却水温外,笔者选取了其他可能影响滤网堵塞的状态参数进行相关性分析,最终选择牵引变流器冷却水入口温度均值、冷却水出口温度均值、新风温度均值、车重均值、变压器原边侧电流均值和中间环路电压这6个变量过去的第1,2,3,5,7,9,12,15,18,22,26 d的均值以及进风口滤网风速共计56个变量作为建模输入变量,主任务输出特征为故障诊断结果0或1;子任务输出特征为滤网堵塞百分比。

3.2 数据集及参数设置

试验仿真数据来源于我国某型动车组牵引变流器车载实时数据和回库检测数据等日常运行维护数据。根据前期的数据分析结果,选取1 800条数据作为建模样本数据。这里将报出冷却系统故障的记录标记为1,未报出故障的记录标记为0,作为主任务故障诊断标签;进风口滤网风速值记为子任务滤网堵塞程度标签值。滤网堵塞数据共计460条,占总体样本的25.6%,样本按照70%和30%的比例作为训练样本和测试样本,即训练集1 260条,测试集540条。

初始化参数设定如下:

1) 神经网络层数及每层节点数。这里输入层56个神经元,主任务输出层1个神经元,子任务输出层1个神经元;

2) 最大迭代次数设置为300次;

3) 优化器采用SGD,使用基于时间的衰减方案调节学习率,初始学习率为0.1;

4) 权重 w 初始化时采用随机的方式;

5) 偏向 b 初始化为 0。

3.3 故障诊断结果分析

多任务神经网络学习迭代次数最大设置为 300 次,笔者采用遍历的方式确定隐层的最佳网络结构,隐层神经元从 100~300,每种结构重复 50 次。图 4 为两种方法准确率对比。从图 4 可以追踪滤网脏堵故障诊断分类网络的训练过程。当隐层神经元 150 为最优,平均损失值最低。当滤网堵塞程度子任务加入到网络后,多任务模型相对于单任务模型,准确率在迭代十几次时快速达到 90% 以上,训练时间明显少于单任务学习。

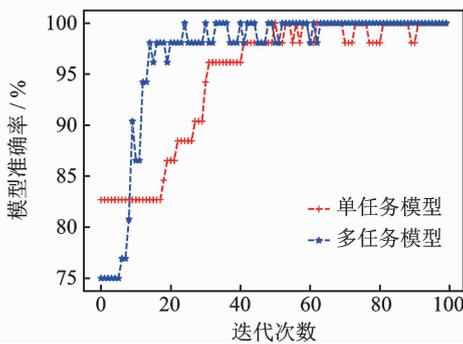


图 4 两种方法准确率对比

Fig. 4 Comparison of accuracy of the two methods

笔者为评估算法性能,选择了 SVM、单任务 DNN 与本研究 MT-DNN 进行比较,其结果如表 1 所示。对于支持向量机模型,采用径向基函数(radial basis function,简称 RBF),通过比较正确率、召回率和 F 值评价性能。可以看出,无论是正确率、召回率还是 F 值,MT-DNN 模型都取得了最好的结果,说明采用多任务学习可以有效提高故障诊断的性能。另外,各个模型预测结果虽然存在一定的差异,但是 F 值都超过了 70%。说明本研究提取的特征较好地预测了故障诊断的结果。

表 1 滤网故障诊断模型性能对比

Tab. 1 Performance comparison of filter fault diagnosis models %

方式	正确率	召回率	F 值
SVM	72.31	76.29	74.45
ST-DNN	75.29	74.78	74.77
MT-DNN	81.24	80.71	80.29

3.4 滤网堵塞退化状态曲线拟合分析

选取包含整个滤网堵塞故障周期的故障样本作为训练数据,应用 MT-DNN 模型提取故障样本特征,将模型提取出的特征作为 SOM 模型的输入变

量,构建多任务滤网堵塞退化状态曲线。SOM 的网络拓扑节点输入节点个数为 150,训练次数为 30,学习率为 0.6。模型训练完成后,为验证退化状态曲线的拟合效果,选取滤网堵塞故障样本,分别将基于 MTDNN-SOM 和单任务深度神经网络状态修模型(single-task deep neural networks-SOM,简称 STDNN-SOM)得到的退化状态曲线经归一化后,与归一化的滤网通风量数据进行对比,如图 5 所示。笔者提出的滤网堵塞退化状态曲线能较好地描述滤网从被清洗到轻微堵塞再到严重堵塞引起故障的整个周期的退化过程,曲线局部震荡较小。相对单任务模型,多任务模型具有更好的趋势性和拟合效果,能够更好地反映滤网堵塞状态变化,为牵引变流器滤网基于状态的清理提供决策依据。

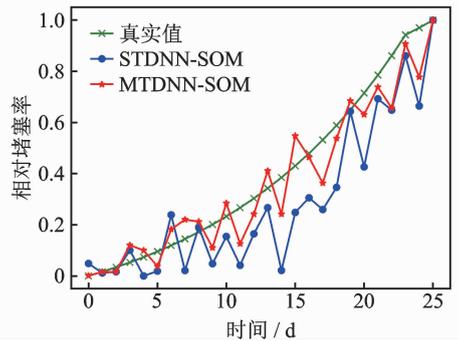


图 5 两种方法拟合效果对比

Fig. 5 Comparison of the fitting effects of the two methods

4 结束语

针对高速列车牵引变流器滤网清理状态修问题,提出一种基于 MTDNN-SOM 的滤网故障诊断和堵塞程度预测模型。针对滤网堵塞引起故障及堵塞状态缓慢变化的特点,采用神经网络构建了滤网故障诊断主任务和滤网堵塞程度子任务的多任务深度学习模型,将实时接收的车载状态数据及列车回库检修数据应用于 MTDNN-SOM 模型进行故障诊断及堵塞程度预测,实现牵引变流器滤网基于状态的清理维修和模型的自适应优化。

针对滤网故障诊断,通过与 SVM、单任务算法的对比,本方法准确性均优于 SVM 和 ST-DNN,训练迭代次数优于 ST-DNN。同时,通过 MT-DNN 提取的故障特征经 SOM 处理得到的滤网堵塞性能退化曲线比 STDNN-SOM 得到性能退化曲线预测的效果更好。因此,笔者所提出的基于 MTDNN-SOM 的滤网故障诊断和堵塞程度预测模型有效可行,可用于牵引变流器滤网清理状态维修决策。

参 考 文 献

- [1] 裴洪, 胡昌华, 司小胜, 等. 基于机器学习的设备剩余寿命预测方法综述[J]. 机械工程学报, 2019, 55(8): 1-13.
PEI Hong, HU Changhua, SI Xiaosheng, et al. Review of machine learning based remaining useful life prediction methods for equipment[J]. Journal of Mechanical Engineering, 2019, 55(8): 1-13. (in Chinese)
- [2] BANGALORE P, TJEMBERG L. An artificial neural network approach for early fault detection of gearbox bearings[J]. IEEE Transactions on Smart Grid, 2017, 6(2): 980-987.
- [3] 蒋强, 沈林, 张伟, 等. 基于深度学习的故障诊断方法研究[J]. 计算机仿真, 2018, 35(7): 409-413.
JIANG Qiang, SHEN Lin, ZHANG Wei, et al. Fault diagnosis method based on deep learning[J]. Computer Simulation, 2018, 35(7): 409-413. (in Chinese)
- [4] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56. (in Chinese)
- [5] KHAN S, YAIRI T. A review on the application of deep learning in system health management[J]. Mechanical Systems and Signal Processing, 2018, 107: 241-265.
- [6] JIA F, LEI Y, LIN J, et al. Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems & Signal Processing, 2016 (72/73): 303-315.
- [7] 邓超, 陶志奎, 吴军, 等. 基于性能退化的数控机床剩余寿命预测[J]. 机械工程学报, 2018, 54(17): 181-189.
DENG Chao, TAO Zhikui, WU Jun, et al. Residual life prediction for NC machine tool based on performance degradation[J]. Journal of Mechanical Engineering, 2018, 54(17): 181-189. (in Chinese)
- [8] CARUANA R. Multitask learning[J]. Machine Learning, 1997, 28(1): 41-75.
- [9] CAI F, CHERKASSKY V. Generalized SMO algorithm for SVM-based multitask learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2012, 23(6): 997-1003.
- [10] 秦晨光, 王海, 任杰, 等. 基于多任务学习的方言语种识别[J]. 计算机研究与发展, 2019, 56(12): 2632-2640
QIN Chenguang, WANG Hai, REN Jie, et al. Dialect language recognition based on multi-task learning[J]. Journal of Computer Research and Development, 2019, 56(12): 2632-2640. (in Chinese)
- [11] 程进, 王坚. 基于多任务学习的炼钢终点预测方法[J]. 计算机应用, 2017, 37(3): 889-895.
CHENG Jin, WANG Jian. Endpoint prediction method for steelmaking based on multi-task learning[J]. Journal of Computer Applications, 2017, 37(3): 889-895. (in Chinese)
- [12] 夏筱筠, 林浒. 基于自学习 SOM 和 ARMA 算法的数控机床滚动轴承健康预警研究[J]. 小型微型计算机系统, 2019, 40(1): 215-220.
XIA Xiaojun, LIN Hu. Research on health warning for rolling bearing of CNC Machine tool based on self-learning SOM and ARMA algorithm[J]. Journal of Chinese Computer Systems, 2019, 40(1): 215-220. (in Chinese)
- [13] 刘兆炜, 王汉军, 李丹, 等. 改进 SOM 神经网络在电力调度故障诊断中的应用[J]. 计算机系统应用, 2018, 27(3): 179-185.
LIU Zhaowei, WANG Hanjun, LI Dan, et al. Application of improved SOM neural network in fault diagnosis of electric power dispatching[J]. Computer Systems & Applications, 2018, 27(3): 179-185. (in Chinese)
- [14] HONG S, ZHOU Z, ZIO E, et al. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method[J]. Digital Signal Processing, 2014, 27(1): 159-166.
- [15] 赵光权, 刘小勇, 姜泽东, 等. 基于深度学习的轴承健康因子无监督构建方法[J]. 仪器仪表学报, 2018, 39(6): 82-87.
ZHAO Guangquan, LIU Xiaoyong, JIANG Zedong, et al. Unsupervised health indicator of bearing based on deep learning[J]. Chinese Journal of Scientific Instrument, 2018, 39(6): 82-87. (in Chinese)



第一作者简介: 顾佳, 女, 1985年10月生, 博士生、高级工程师。主要研究方向为先进生产制造技术及模式、故障诊断与预测等。

E-mail: gujiafirst@163.com